

**OTÁVIO MIRANDA VERLY**

**SENSORIAMENTO REMOTO NA ESTIMATIVA DO ESTOQUE DE CARBONO EM  
FRAGMENTOS FLORESTAIS DA MATA ATLÂNTICA**

Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Ciência Florestal, para obtenção do título de *Magister Scientiae*.

Orientador: Laércio Antônio Gonçalves Jacovine

**VIÇOSA - MINAS GERAIS  
2021**

**Ficha catalográfica elaborada pela Biblioteca Central da Universidade  
Federal de Viçosa - Campus Viçosa**

T

V521s Verly, Otávio Miranda, 1996-  
2021 Sensoriamento remoto na estimativa do estoque de carbono  
em fragmentos florestais da Mata Atlântica / Otávio Miranda  
Verly. – Viçosa, MG, 2021.  
1 dissertação eletrônica (55 f.): il. (algumas color.).

Inclui apêndice.

Orientador: Laércio Antônio Gonçalves Jacovine.

Dissertação (mestrado) - Universidade Federal de Viçosa.

Referências bibliográficas: f. 46-53.

DOI: <https://doi.org/10.47328/ufvbbt.2021.077>

Modo de acesso: World Wide Web.

1. Levantamentos florestais. 2. Estatística não-paramétrica.  
3. Sucessão florestal. I. Universidade Federal de Viçosa.  
Departamento de Engenharia Florestal. Programa de  
Pós-Graduação em Ciência Florestal. II. Título.

CDO adapt. CDD 634.953

Bibliotecário(a) responsável: Renata de Fátima Alves CRB6/2578

**OTÁVIO MIRANDA VERLY**

**SENSORIAMENTO REMOTO NA ESTIMATIVA DO ESTOQUE DE CARBONO EM  
FRAGMENTOS FLORESTAIS DA MATA ATLÂNTICA**

Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Ciência Florestal, para obtenção do título de *Magister Scientiae*.

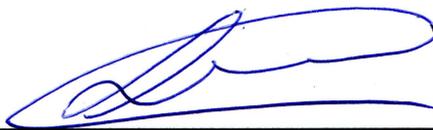
APROVADA: 26 de julho de 2021.

Assentimento:



---

Otávio Miranda Verly  
Autor



---

Laércio Antônio Gonçalves Jacovine  
Orientador

Aos meus pais, amigos, professores e à Natureza....

... Com carinho dedico.

## AGRADECIMENTOS

A Deus, ao Universo, e à Natureza, pelo dom da vida e pela grata oportunidade de estudar as florestas brasileiras com tanto afinho e paixão.

Aos meus pais, Dolcimar Leite Verly e Margarida Miranda da Silva Verly, pelo amor incondicional e apoio inabalável, me fazendo e mantendo como o homem, cidadão, e profissional que hoje sou. Por todos os prantos que me enxugaram, minha eterna gratidão!

À minha irmã Andréia Miranda Verly, ao cunhado Gileno Gomes da Silva, e sobrinha Alice Gomes Verly, por também creditarem bons sentimentos à conquista deste sonho.

À bela existência e inesquecível memória da amada avó Nadir Leite Verly.

A todos os familiares que por mim torceram e oraram, em especial à minha querida avó Alice Mariana.

A todos os professores que me oportunizaram vislumbrar os diferentes horizontes existentes em cada mundo infinito contido em seus conhecimentos, e me ajudaram a construir o meu próprio cosmos interior.

Aos amados amigos que a UFV me trouxe, Bruno Gomes de Noronha, Eliana Boaventura Bernardes Moura Alves, Fernanda Raquel Lambrecht, Indira Bifano Comini, Luana de Souza Covre, Thaynara Pereira Albuquerque, Samuel José Silva Soares da Rocha, Simone Silva, Valéria de Fátima Silva e Veronica Cañas Mesa, os quais colaboraram direta e indiretamente com esta pesquisa e sempre terão minha fiel amizade, e, por quem meu coração sempre se alegrará com suas conquistas.

Aos colegas Carlos Alberto Ramos Domiciano, Ivaldo da Silva Tavares Junior, Kemely Alves Atanzio, Rodrigo Vieira Leite, e demais colegas de departamento, pela ajuda valorosa nos momentos que precisei.

Aos acadêmicos estagiários: Isabella Ferreira Lauria, Rodrigo Alves Rodello e Vinícius Tobias Leandro Lucila, pela grande contribuição nas coletas e trabalhos de campo, sem a qual este trabalho não seria possível.

Ao Departamento de Engenharia Florestal – DEF, em especial ao Prof. Dr. Carlos Moreira Miquelino Eleto Torres, que me abriu as portas para que eu pudesse trilhar esta caminhada.

Ao PPG em Ciência Florestal, em nome de Alexandre Amorim da Silva, cujo empenho em seu trabalho na secretaria da pós-graduação colaborou para que ardor desta caminhada fosse suavizado.

Ao GEEA, em nome de Águida Beatriz Travaglia Viana, Frederico Dalton Souza, Isabella Salgado Faustino e Thaís de Almeida Rocha, que colaboraram imensamente para a realização deste trabalho.

Ao Departamento de Engenharia Civil, em nome do Prof. Dr. Antônio Santana Ferraz e do técnico Tiago Oliveira Lopes, pela colaboração na execução deste estudo.

Aos professores doutores Cibele Hummel do Amaral, Hélio Garcia Leite e José Marinaldo Gleriani, pelas contribuições neste trabalho.

Ao grato privilégio de ter sido orientado pelo querido Prof. Dr. Laércio Antônio Gonçalves Jacovine, o qual sempre terá minha admiração pela irrefutável competência profissional e pelo carinho com seus orientados.

À banca avaliadora, pelas valiosas contribuições para que pudesse apresentar este trabalho em sua melhor versão.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pela concessão de bolsa de mestrado – Código de Financiamento 144356/2019-8.

Por fim, agradeço a todos que não foram aqui enaltecidos, mas que desejaram e contribuíram para minha simplória, porém sólida conquista.

*“O homem pode tanto quanto sabe.”*  
(Francis Bacon)

## RESUMO

VERLY, Otávio Miranda, M.Sc., Universidade Federal de Viçosa, julho de 2021. **Sensoriamento remoto na estimativa do estoque de carbono em fragmentos florestais da Mata Atlântica.** Orientador: Laércio Antônio Gonçalves Jacovine.

O aumento da concentração atmosférica de gases poluentes preocupa a comunidade internacional, que estabeleceu metas de controle das mudanças climáticas. As florestas são um componente importante neste processo, pois capturam parte destes gases. Métodos de inventários tradicionais são onerosos e ineficazes em áreas extensas, ao passo que estimativas baseadas em sensoriamento remoto podem fornecer uma contabilização precisa dos estoques de carbono. Objetivou-se avaliar o potencial de variáveis de sensoriamento remoto de alta resolução espacial na estimação do estoque de carbono em fragmentos da Mata Atlântica. As áreas nativas da Universidade Federal de Viçosa, *Campus Viçosa*, foram classificadas em três estágios sucessionais, onde foram estabelecidas 10 parcelas (20x50 m). Foram obtidos a altura total (*Ht*) e o diâmetro a 1,3 m de altura (*dap*) dos indivíduos arbóreo-arbustivos com  $dap \geq 5,0$  cm. O estoque de carbono foi estimado com o modelo de Schumacher e Hall ajustado para a vegetação secundária da região. Foram utilizadas imagens do satélite Sentinel-2, com resolução de 10 m, dos períodos seco e chuvoso. Foram obtidas sete variáveis espectrais: as reflectâncias das bandas Azul, Verde, Vermelho e Infravermelho Próximo, além dos Índices de Vegetação (IVs) *Enhanced Vegetation Index*, *Normalized Difference Vegetation Index* e *Soil Adjusted Vegetation Index*. A correlação entre as variáveis e o estoque de carbono foi verificada pela Correlação de Pearson. Foram treinadas Redes Neurais Artificiais (RNA) do tipo *Multilayer Perceptron* (MLP) com diferentes combinações de variáveis. A validação das RNA foi feita com 1.000 valores simulados para cada variável de entrada. O carbono foi modelado com a RNA de melhor desempenho no treinamento e validação. Foram inventariados 4.114 indivíduos e 4.579 fustes. O estrato intermediário apresentou maior número de indivíduos (36,83%) e de fustes (36,34%). A *Ht* média foi de 9,74, 9,55 e 11,98 m e o diâmetro quadrático (*Dq*) de 11,33, 10,68 e 12,91 cm, nos estratos inicial, intermediário e avançado, respectivamente. Nesta ordem, o estoque de carbono médio amostrado foi 24,99, 35,79 e 82,28 Mg ha<sup>-1</sup>, e média geral 47,68 Mg ha<sup>-1</sup>. A distribuição diamétrica apresentou o padrão J-invertido em todos os estratos sucessionais. As classes diamétricas < 25 cm contribuíram com 62,92% do estoque de carbono no estrato inicial e 52,20% no intermediário. No estrato avançado indivíduos  $\geq 25$  cm representaram 79,73% do estoque. As variáveis do período chuvoso apresentaram melhores correlações com o carbono estocado. A RNA treinada com as reflectâncias do período chuvoso

apresentou bom desempenho, e foi selecionada para validação e estimativa do carbono da área. O desempenho das RNA no treinamento não foi melhorado com a adição dos IVs. Os dados espectrais simulados foram consistentes e adequados para validação da RNA selecionada. O estoque total de carbono obtido pela modelagem da RNA foi de 41.962,15 Mg. Os valores variaram de 6,68 a 108,29 Mg ha<sup>-1</sup>, e média de 48,70 Mg ha<sup>-1</sup>. A metodologia utilizada é eficiente, e pode direcionar a contabilização acurada do carbono e o estabelecimento de práticas e políticas voltadas à mitigação das mudanças climáticas.

Palavras-chave: Estrutura florestal. Inventário florestal. Modelagem não-paramétrica. Sentinel-2. Sucessão florestal.

## ABSTRACT

VERLY, Otávio Miranda, M.Sc., Universidade Federal de Viçosa, July 2021. **Remote sensing in the estimation of the carbon stock in forest fragments of the Atlantic Forest.** Advisor: Laércio Antônio Gonçalves Jacovine.

The increase in the atmospheric concentration of polluting gases worries the international community, which has set targets for controlling climate change. Forests are an important component in this process, as they capture part of these gases. Traditional inventory methods are costly and infeasible over large areas, while estimates based on remote sensing can provide an accurate accounting of carbon stocks. This study aimed to evaluate the potential of high spatial resolution remote sensing variables in the estimation of carbon stock in Atlantic Forest fragments. The native areas of the Universidade Federal de Viçosa, *Campus Viçosa*, were classified into three successive stages, where 10 plots (20x50 m) were established. Total height (*Ht*) and diameter at 1.3 m in height (*dgh*) of arboreal-shrubby individuals with  $dgh \geq 5.0$  cm were obtained. The carbon stock was estimated using the Schumacher and Hall model adjusted for secondary vegetation in the region. Sentinel-2 satellite images, with a resolution of 10 m, of the dry and rainy periods were used. Seven spectral variables were obtained: the reflectance of the Blue, Green, Red and Near Infrared bands, in addition to the Vegetation Indices (VIs) Enhanced Vegetation Index, Normalized Difference Vegetation Index and Soil Adjusted Vegetation Index. The correlation between variables and carbon stock was verified by Pearson's correlation. Multilayer Perceptron (MLP) Artificial Neural Networks (ANN) were trained with different combinations of variables. ANN validation was performed with 1,000 simulated values for each input variable. Carbon was modeled with the ANN with the best performance in training and validation. 4,114 individuals and 4,579 stems were inventoried. The intermediate stratum had a greater number of individuals (36.83%) and stems (36.34%). The average *Ht* was 9.74, 9.55 and 11.98 m and the quadratic diameter (*Dq*) of 11.33, 10.68 and 12.91 cm, in the initial, intermediate, and advanced strata, respectively. In this order, the average carbon stock sampled was 24.99, 35.79 and 82.28 Mg ha<sup>-1</sup>, and overall average 47.68 Mg ha<sup>-1</sup>. Diametric distribution presented the inverted-J pattern in all successional strata. Diametric classes < 25 cm contributed 62.92% of the carbon stock in the initial stratum and 52.20% in the intermediate. In the advanced stratum, individuals  $\geq 25$  cm represented 79.73% of the stock. The rainy period variables showed better correlations with the stored carbon. The ANN trained with the rainy season reflectances performed well and was selected for validation and estimation of the area's carbon. The performance of ANNs in training was not improved

with the addition of IVs. The simulated spectral data were consistent and adequate to validate the selected ANN. The total carbon stock obtained by ANN modeling was 41,962.15 Mg. Values ranged from 6.68 to 108.29 Mg ha<sup>-1</sup>, with an average of 48.70 Mg ha<sup>-1</sup>. The methodology used is efficient and can guide accurate carbon accounting and the establishment of practices and policies aimed at mitigating climate change.

Keywords: Forest inventory. Forest structure. Forest succession. Non-parametric modeling. Sentinel-2.

## SUMÁRIO

<b>1.</b>	<b>INTRODUÇÃO</b> .....	12
<b>2.</b>	<b>MATERIAL E MÉTODOS</b> .....	14
2.1.	DESCRIÇÃO DA ÁREA DE ESTUDO.....	14
2.2.	DESCRIÇÃO DA PESQUISA.....	16
<b>2.2.1.</b>	<b>Inventário Florestal</b> .....	16
2.2.1.1.	Estratificação dos Fragmentos Florestais.....	16
2.2.1.2.	Aleatorização e Georreferenciamento das Parcelas.....	17
2.2.1.3.	Coleta de Dados.....	17
2.2.1.4.	Estimativas de Carbono com Modelagem Alométrica.....	17
<b>2.2.2.</b>	<b>Processamento das Variáveis Espectrais</b> .....	18
2.2.2.1.	Seleção e Obtenção de Imagens Orbitais.....	18
2.2.2.2.	Processamento das Variáveis.....	18
2.2.2.3.	Seleção das Variáveis.....	19
<b>2.2.3.</b>	<b>Seleção das Redes Neurais Artificiais</b> .....	19
2.2.3.1.	Treinamento.....	19
2.2.3.2.	Avaliação de Desempenho.....	20
<b>2.2.4.</b>	<b>Validação e Aplicação das Redes Neurais Artificiais</b> .....	21
2.2.4.1.	Validação.....	21
2.2.4.2.	Mapeamento do Estoque de Carbono.....	22
<b>3.</b>	<b>RESULTADOS</b> .....	22
3.1.	ESTRUTURA FLORESTAL.....	22
3.2.	CORRELAÇÃO DAS VARIÁVEIS.....	25
3.3.	REDES NEURAIS ARTIFICIAIS.....	27
<b>3.3.1.</b>	<b>Treinamento</b> .....	27
<b>3.3.2.</b>	<b>Validação</b> .....	31
3.4.	MAPEAMENTO DO ESTOQUE DE CARBONO.....	32
<b>4.</b>	<b>DISCUSSÃO</b> .....	34
4.1.	ESTRUTURA FLORESTAL.....	34
4.2.	ESTOQUE DE CARBONO.....	37
4.3.	VARIÁVEIS ESPECTRAIS E O ESTOQUE DE CARBONO.....	39
4.4.	MODELAGEM DO ESTOQUE DE CARBONO.....	42
<b>5.</b>	<b>CONCLUSÃO</b> .....	45
	<b>REFERÊNCIAS</b> .....	46

## 1. INTRODUÇÃO

Desde a revolução industrial o ritmo de globalização e degradação ambiental assumem escalas assustadoras, as quais têm acelerado as mudanças climáticas em nível global (FOSTER; ROYER; LUNT, 2017). Em contrapartida, articulações internacionais têm implementado mecanismos ambientais e econômicos voltados à redução dos efeitos destas mudanças. Neste contexto, merece destaque o Protocolo de Quioto, que foi adotado na Conferência das Partes (COP) da Convenção-Quadro das Nações Unidas sobre a Mudança do Clima (UNFCCC) de 1997, sendo uma de suas ferramentas o Mecanismo de Desenvolvimento Limpo (MDL), que foi aplicado pelos países em desenvolvimento (OLIVEIRA; MIGUEZ; ANDRADE, 2018). Ressalta-se também o Acordo de Paris, que foi estabelecido em 2015, durante a 21ª Conferência da Convenção-Quadro das Nações Unidas (COP 21) em Paris, em que os países signatários estabeleceram novas metas e mecanismos para a redução das mudanças climáticas (BITTENCOURT; BUSCH; CRUZ, 2018).

O Brasil protagonizou papéis de destaque nas convenções e propostas relacionadas ao clima. As ideias apresentadas embasaram ações consideráveis, tanto do Protocolo de Quioto quanto do Acordo de Paris (BITTENCOURT; BUSCH; CRUZ, 2018). Com vistas à ratificação do Protocolo de Quioto em 2005, e após a COP de Copenhague, em 2009, foi criada a Lei Nº 12.187, de 29 de dezembro de 2009, que institui a Política Nacional de Mudanças Climáticas (PNMC) (BRASIL, 2009). Embora as atividades ligadas ao MDL tenham se iniciado anos antes da criação desta lei, a sua implementação permitiu ao Brasil vislumbrar o estabelecimento ou consolidação de outros mecanismos que auxiliariam o alcance das metas estabelecidas (BITTENCOURT; BUSCH; CRUZ, 2018; MELO e SILVA, 2018). Citam-se o Programa para Redução da Emissão de Gases de Efeito Estufa na Agricultura (Programa ABC) e as iniciativas das Contribuições Nacionalmente Determinadas (NDCs), que visam reduzir as emissões em 36% até 2025, por meio da eliminação do desmatamento ilegal na Amazônia e da recuperação de 12 milhões de hectares de áreas degradadas até 2030 (MARQUES, 2018; MELO e SILVA, 2018).

O destaque brasileiro nos acordos climáticos é fundamentalmente importante, uma vez que as florestas tropicais são cruciais para o ciclo do Carbono no planeta, pois são responsáveis por um estoque de 228,7 Pg (BACCINI et al., 2012). No Brasil, a Mata Atlântica possui apenas 26% de cobertura florestal nativa, composta de áreas de floresta primária e de vegetação secundária (REZENDE et al., 2018), e ainda sofre com perdas significativas da riqueza de

espécies e de biomassa devido às atividades antrópicas (LIMA et al., 2020). O estudo destes estoques e sua relação dinâmica com os ecossistemas e o clima são os precursores das iniciativas nacionais e mundiais de controle das mudanças climáticas, uma vez que sua degradação promove prejuízos ambientais e econômicos (LIMA et al., 2020).

A biomassa florestal aérea é altamente correlacionada com o estoque de carbono, e ambos são fatores primordiais na compreensão do ciclo do carbono (Zhu e Liu, 2015; ZHANG et al., 2019). Assim, a contabilização acurada destes componentes é importante para diferentes áreas do setor florestal, pois subsidia cientificamente o manejo florestal sustentável (WILSON; WOODALL; GRIFFITH, 2013; GÜNERALP; FILIPPI; RANDALL, 2014; ZALD et al., 2016). Estudos com esse enfoque são fundamentais na avaliação do impacto dos distúrbios antrópicos na dinâmica florestal e no ciclo do carbono, e as consequências relacionadas às mudanças climáticas (GÜNERALP; FILIPPI; RANDALL, 2014; BOUCHER et al., 2020; REX et al., 2020).

O cumprimento das metas dos acordos climáticos exige que as estimativas produzidas na modelagem da biomassa florestal aérea e o estoque de carbono correspondente sejam acuradas, e forneçam um inventário preciso destes componentes. Contudo, a determinação do estoque de carbono em ecossistemas florestais por meio de inventários tradicionais demanda um aparato expressivo de mão-de-obra e equipamentos (ANAYA; CHUVIECO; PALACIOS-ORUETA, 2009; ZHU e LIU, 2015), o que limita a frequência espacial e temporal de amostragem (POWELL et al., 2010; ZALD et al., 2016). Assim, utilizar apenas variáveis oriundas de levantamentos de campo pode acarretar vieses e a consequente redução da qualidade das estimativas realizadas acerca da dinâmica do carbono florestal, o que impossibilita o acompanhamento adequado dos processos ligados ao estoque e ciclo do carbono nos ecossistemas florestais (MAIN-KNORN et al., 2011; 2013; MOLINA et al., 2016).

O inventário do estoque de biomassa e carbono florestais com uso de dados de sensoriamento remoto têm sido realizados com sucesso desde meados da década de 1980 (LU, 2006). Desde então, as técnicas de predição vêm recebendo um aporte significativo no campo da pesquisa (ANAYA; CHUVIECO; PALACIOS-ORUETA, 2009; LU et al., 2016). O aprimoramento tecnológico de diferentes sensores remotos tem permitido a contabilização precisa dos estoques florestais, em escalas cada vez maiores. Além disso, sensores passivos orbitais produzem séries temporais de dados ópticos capazes de evidenciar as flutuações da biomassa vegetal (BRANDT et al., 2012; MAIN-KNORN et al., 2013; PFLUGMACHER et al., 2014), o que tem propiciado o acompanhamento permanente dos estoques florestais de

carbono (WILSON; WOODALL; GRIFFITH, 2013). Estes avanços contribuem para compreensão do ciclo global do carbono e subsidiam as iniciativas internacionais de redução das emissões de gases de efeito estufa (GEE), como o programa das Nações Unidas para Redução de Emissões por Desmatamento e Degradação Florestal (REDD +) (GIBBS et al., 2007; LAURIN et al., 2014; REX et al., 2020), além da geração de créditos de carbono no âmbito do MDL (OLIVEIRA; MIGUEZ; ANDRADE, 2018).

O uso de sensoriamento remoto passivo para modelagem do estoque de carbono, geralmente tem se baseado em dados de resolução espacial menor (pixel  $\geq 30$  m). Poucos estudos avaliaram a utilização de dados de alta resolução para esta aplicação em florestas tropicais. Neste contexto, estudos que visem avaliar a aplicabilidade de dados ópticos oriundos de novos sensores de alta resolução são fundamentais para garantir o avanço de metodologias de contabilização dos estoques de biomassa e carbono, e compreensão da dinâmica florestal relacionada a estes componentes em florestas secundárias. A demonstração da aplicabilidade destes dados é especialmente importante para a Mata Atlântica, por se tratar de um bioma altamente antropizado.

O objetivo deste estudo foi avaliar o potencial de aplicação de variáveis de sensoriamento remoto passivo de alta resolução espacial na estimação do estoque total de carbono aéreo em fragmentos de Mata Atlântica. Os objetivos específicos são: i) caracterizar a estrutura florestal nos diferentes estágios sucessionais; ii) contabilizar o estoque de carbono florestal aéreo em áreas nativas da Mata Atlântica, a partir de modelagem alométrica baseada em dados de campo; iii) avaliar o poder preditivo de variáveis ópticas oriundas do satélite Sentinel-2 na modelagem do estoque de carbono florestal aéreo; e, iv) averiguar a eficiência de modelagem não-paramétrica na estimativa do estoque de carbono a partir de dados de sensoriamento remoto passivo.

## **2. MATERIAL E MÉTODOS**

### **2.1. DESCRIÇÃO DA ÁREA DE ESTUDO**

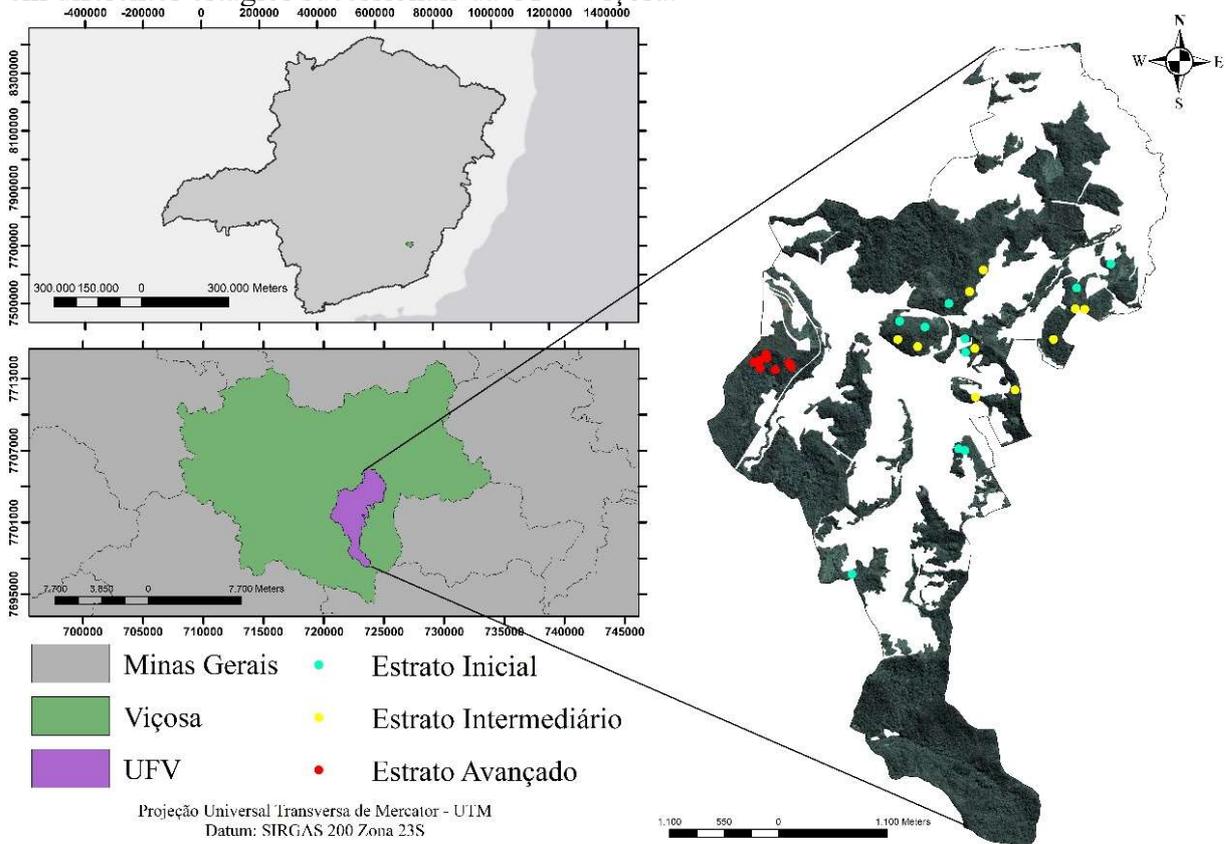
O estudo considerou os fragmentos pertencentes à Universidade Federal de Viçosa (UFV), *campus* Sede (doravante denominada UFV Viçosa). A área está localizada na porção Sudeste do município de Viçosa e possui 1.646,55 ha (ALMEIDA et al., 2016), dos quais 861,66 ha correspondem a fragmentos de Mata Atlântica ou plantios florestais abandonados. A

topografia da região é acidentada, com relevo caracterizado como forte ondulado e montanhoso, com vales estreitos e altitudes entre 600 e 970 m. A pedologia do município é composta por duas classes de solo principais. Nas encostas e topos de elevações há predomínio de Latossolo Vermelho-Amarelo álico, ao passo que os terraços fluviais são dominados pelos Argissolo Vermelho-Amarelo Câmbico (REZENDE, 1971; CORREA, 1984).

Para a classificação de Köppen o clima da região é do tipo Cwb, caracterizado pelos verões quentes e chuvosos, e invernos frios e secos. A temperatura média, a umidade relativa média e a precipitação anual são 24,9°C, 79% e 1.274 mm, respectivamente (UFV, 2016).

A vegetação nativa da região é classificada como Floresta Estacional Semidecidual Montana (VELOSO; RANGEL-FILHO; LIMA, 1991). O componente florestal nativo da UFMG é composto por fragmentos de extensão variável (Figura 1), classificados como florestas secundárias residuais, em estágios sucessionais variados, oriundos de diferentes atividades e intensidades de uso antrópico (LEAL-FILHO, 1992).

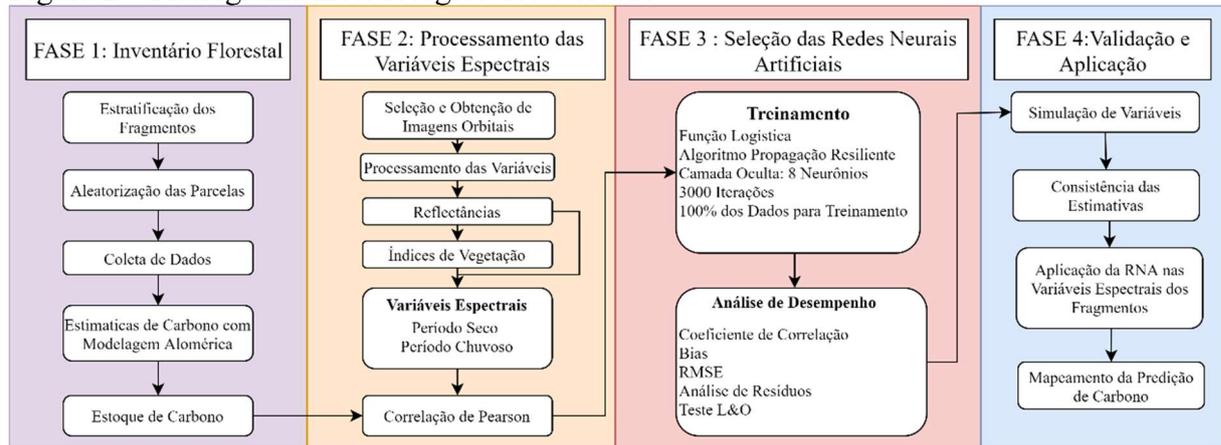
Figura 1 – Distribuição das parcelas amostradas nos fragmentos florestais de Mata Atlântica em diferentes estágios sucessionais da UFV Viçosa.



## 2.2. DESCRIÇÃO DA PESQUISA

O resumo da estrutura metodológica desenvolvida para esta pesquisa é apresentado na Figura 2.

Figura 2 – Fluxograma metodológico deste estudo.



### 2.2.1. Inventário Florestal

#### 2.2.1.1. Estratificação dos Fragmentos Florestais

Estudos indicam que variações significativas das condições florestais podem gerar erros de estimativa em áreas com grandes amplitudes dos valores de biomassa (MAIN-KNORN et al., 2011; ZHU e LIU, 2015). A estratificação dos principais perfis florestais da área analisada colabora para a redução destes efeitos (ANAYA; CHUVIECO; PALACIOS-ORUETA, 2009; BRANDT et al., 2012). A fim de minimizar os erros de estimativa oriundos desta variação, as áreas florestais foram estratificadas em três níveis de sucessão secundária: i) inicial, ii) intermediário, e iii) avançado. Inicialmente, imagens de satélite, atuais e históricas, foram analisadas a fim de se categorizar as áreas a partir da evolução sucessional dos fragmentos. Sequencialmente, as áreas foram percorridas para confrontar as observações de campo com a estratificação inicial, e então os conflitos de classificação foram adequados de acordo com aspectos visuais dos fragmentos.

#### 2.2.1.2. Aleatorização e Georreferenciamento das Parcelas

A partir da estratificação foram estabelecidas aleatoriamente em campo 10 parcelas para cada estrato (Figura 1). As dimensões das unidades amostrais foram de 20x50 m (0,1 ha), conforme implementado por outros estudos conduzidos na UFV Viçosa (AMARO, 2010; AMARO et al., 2013; ROCHA et al., 2020). Um total de 3,0 ha foi amostrado, com uma intensidade amostral (razão área total/área amostrada) de 287:1. Esta intensidade amostral é superior à de diferentes estudos de biomassa e carbono aéreos com base em dados de sensoriamento remoto (WATZLAWICK; KIRCHNER; SANQUETTA, 2009; BARBOSA et al. 2014; LAURIN et al., 2017), e tende a proporcionar maior qualidade às estimativas realizadas.

A obtenção precisa da localização das parcelas é fundamental para que os dados de campo sejam corretamente relacionados com os valores obtido a partir das variáveis remotas, o que resulta em maior acurácia (WILSON; WOODALL; GRIFFITH, 2013; LU et al., 2016). No presente estudo, os vértices das parcelas foram georreferenciados com equipamento GNSS Javad Trimph-1, obtendo as coordenadas com precisão nominal de 3 mm, e período de ocupação mínimo de 25 minutos.

#### 2.2.1.3. Coleta de Dados

Os indivíduos arbóreo-arbustivos e palmeiras vivos com Diâmetro a Altura do Peito mínimo de 5 cm ( $d_{ap} \geq 5$  cm) foram inventariados, conforme implementado em outros estudos realizados nos fragmentos da UFV Viçosa (AMARO et al., 2013; CALIMAN et al., 2020; ROCHA et al., 2020). A Circunferência à Altura do Peito ( $c_{ap}$ ) foi aferida por meio de fita métrica com escala milimétrica. A altura total ( $Ht$ ) foi obtida com um hipsômetro digital Vertex IV. O diâmetro quadrático ( $Dq$ ) e as médias do número de indivíduos, número de fustes,  $Ht$  média e área basal por parcela foram obtidos e comparados pelo teste de Tukey a 5% de probabilidade ( $\alpha \leq 0,05$ ).

#### 2.2.1.4. Estimativas de Carbono com Modelagem Alométrica

Os modelos de predição de carbono florestal aéreo obtidos com dados remotos necessitam ser validados com base no estoque inventariado em amostras da floresta, o qual é

frequentemente calculado a partir dos dados de altura e *dap* (LU, 2005). Os modelos alométricos para realização das estimativas dos estoques devem ser adequadamente selecionados, visto que seu uso inapropriado é uma das maiores fontes de incerteza no processo de modelagem (LU et al., 2016). O estoque de carbono por fuste foi determinado com base no modelo exponencial de Schumacher e Hall (Equação 1) ajustado por Amaro (2010). O autor realizou o ajuste com base em um banco de dados da Mata da Silvicultura, e coeficiente de determinação ajustado ( $R^2\%$ ) da equação é de 94,74%.

$$CF_{CC} = 0,010045 \cdot dap^{2,484657} \cdot Ht^{0,428609} \quad (\text{Equação 1})$$

onde:  $CF_{CC}$  – carbono do fuste com casca (em Kg); *dap* – diâmetro a altura do peito (em cm); e *Ht* – altura total do indivíduo (em m).

Após a obtenção do estoque individual os valores foram convertidos em Mg (toneladas) de carbono por hectare ( $Mg\ ha^{-1}$ ). As médias dos estratos foram comparadas pelo teste de Tukey a 5% de probabilidade ( $\alpha \leq 0,05$ ).

## 2.2.2. Processamento das Variáveis Espectrais

### 2.2.2.1. Seleção e Obtenção de Imagens Orbitais

Os dados ópticos do satélite Sentinel-2 são coletados pelo sensor *MultiSpectral Instrument* (MSI), cuja resolução espacial é de 10 (canais 2, 3, 4 e 5), 20 ou 60 (1, 9 e 10) metros, resolução espectral de 13 bandas, radiométrica de 12 bits e temporal de 5 dias (DRUSCH et al., 2012, ESA, 2015). A fim de avaliar a variação sazonal e o seu potencial preditivo da resposta espectral em diferentes períodos do ano, uma cena para estação seca (26/08/2020) e outra para a estação chuvosa (14/12/2020) foram selecionadas. A seleção das imagens foi baseada na cobertura de nuvens inferior a 30%, e o nível de processamento 2A (correção atmosférica e ortorretificação). A aquisição foi realizada gratuitamente pelo portal Copernicus Open Access Hub (<https://scihub.copernicus.eu/dhus/#/home>).

### 2.2.2.2. Processamento das Variáveis

Diferentes variáveis espectrais podem ser implementadas em modelos preditores de carbono. Foram utilizados a reflectância superficial de quatro bandas espectrais e três Índices de Vegetação (IV) (Tabela 1). Estas variáveis são comumente empregadas para estimativa de

biomassa e carbono florestais em diferentes ecossistemas florestais, incluindo a Mata Atlântica (BARBOSA et al., 2014; CASSOL; SALDANHA; KUPLICH, 2014; FERRAZ et al., 2014; SILVEIRA et al., 2021). O processamento das imagens foi realizado no *software* ArcMap 10.4.1 ESRI®. Os IVs foram calculados com a função *Raster Calculator*, e as estatísticas das variáveis obtidas com a ferramenta *Zonal Statistics to Table*.

Tabela 1 – Variáveis espectrais obtidas de imagens Sentinel-2 utilizadas como variáveis de entrada em Redes Neurais Artificiais para estimativa do estoque de carbono dos fragmentos florestais nativos da UFV Viçosa.

Banda/Índice	Variável Espectral	Comprimento de Onda Central/ Equação	Referência
BLUE	Reflectância na banda azul	490 µm	–
GREEN	Reflectância na banda verde	560 µm	–
RED	Reflectância na banda vermelho	665 µm	–
NIR	Reflectância na banda infravermelho próximo	842 µm	–
EVI	<i>Enhanced Vegetation Index</i>	$2.5 \frac{\text{NIR} - \text{RED}}{\text{NIR} + 6\text{RED} - 7.5 \text{BLUE} + 1}$	HUETE; JUSTICE; LIU, 1994
NDVI	<i>Normalized Difference Vegetation Index</i>	$\frac{\text{NIR} - \text{RED}}{\text{NIR} + \text{RED}}$	ROUSE-JUNIOR et al., 1973
SAVI	<i>Soil Adjusted Vegetation Index</i>	$\frac{\text{NIR} - \text{RED}}{\text{NIR} + \text{RED} + L} (1+L)$	HUETE, 1988

Nota: L = 0,5.

### 2.2.2.3. Seleção das Variáveis

As relações entre as variáveis, e entre variáveis e o estoque de carbono foram avaliadas pela Correlação de Pearson a 5% de significância. Para a proposição das Redes Neurais Artificiais (RNA) foram selecionadas as variáveis com maior correlação com estoque de carbono observado e menor correlação com outras variáveis espectrais.

### 2.2.3. Seleção das Redes Neurais Artificiais

#### 2.2.3.1. Treinamento

As RNA treinadas foram do tipo *Multilayer Perceptron* (MLP), implementadas com o emprego do algoritmo de treinamento *Resilient Propagation* (Rprop) (RIEDMILLER e

BRAUN, 1993) e função de ativação Logística. Estes são parâmetros de RNA apontados como eficientes na modelagem de diferentes variáveis florestais (CAMPOS e LEITE, 2017). O número de neurônios na camada de entrada variou entre 3 e 7, conforme utilização das diferentes combinações das variáveis que apresentaram melhor correlação com o estoque de carbono. O treinamento foi realizado com 100% das amostras, e 8 neurônios na camada oculta, assumindo que esse número não apresenta risco de memorização dos dados. A camada de saída continha um neurônio, correspondente ao carbono estimado. Para cada conjunto de variáveis testado foram treinadas 50 RNA, e os critérios de parada foram 3.000 iterações, ou erro médio igual a 0,0001, ou convergência igual a 20. O *software* utilizado no treinamento foi o Neuro4® (BINOTI, 2012).

#### 2.2.3.2. Avaliação de Desempenho

A análise das incertezas das estimativas é fundamental para compreender o desempenho estatístico dos diferentes métodos de modelagem, e pode ser realizada por diferentes meios. Esta avaliação é imprescindível para subsidiar a melhoria das estimativas e quantificações do estoque de carbono, além de nortear as tomadas de decisões no manejo florestal em diferentes escalas (GÜNERALP; FILIPPI; RANDALL, 2014; LU et al., 2016).

A acurácia das estimativas foi verificada pelos seguintes indicadores: coeficiente de correlação (R), raiz quadrada do erro quadrático médio (RMSE), e *Bias* (equações 2 a 4). Trata-se de métodos amplamente empregados para verificação do desempenho estatístico de métodos paramétricos e não-paramétricos empregados na estimativa de biomassa/carbono florestal (ZOLKOS; GOETZ; DUBAYAH, 2013; GÜNERALP; FILIPPI; RANDALL, 2014; ZHU e LIU, 2015; ZALD et al., 2016; ALMEIDA et al., 2020).

$$R = \frac{\sum (y_i - \bar{y}_i)(\hat{y}_i - \bar{\hat{y}}_i)}{\sqrt{\sum (y_i - \bar{y}_i)^2 \sum \hat{y}_i - \bar{\hat{y}}_i)^2}} \quad (\text{Equação 2})$$

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (\text{Equação 3})$$

$$\text{Bias} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i) \quad (\text{Equação 4})$$

onde: SQ é a soma dos quadrados;  $y_i$  e  $\hat{y}_i$  são, respectivamente, o carbono observado e o carbono estimado na amostra  $i$ , e  $n$  é o número total de amostras.

A performance dos métodos de estimação também foi avaliada pela análise gráfica da dispersão do erro relativo percentual (ER%) (CAMPOS e LEITE, 2017), assim como empregado em outros estudos de modelagem de biomassa e carbono florestal (Almeida et al., 2020; Domingues et al., 2020). A significância das diferenças entre os valores estimados e observados foi avaliada pelo teste L&O (LEITE e OLIVEIRA, 2002).

## 2.2.4. Validação e Aplicação das Redes Neurais Artificiais

### 2.2.4.1. Validação

A RNA selecionada foi validada por meio de sua aplicação em dados simulados. Esta técnica confere ganho em relação ao prejuízo do treino realizado com uma pequena quantidade de dados e o uso de uma subamostra para validação. Foram simulados 1.000 valores de reflectância das bandas BLUE, GREEN, RED e NIR, conforme as equações 5 a 8:

$$BLUE_s = \alpha + (AI*2) - \left(\frac{AI}{3}\right) - (AI_{1,5} * AI) \quad (\text{Equação 5})$$

$$GREEN_s = (1,6988 * BLUE_s) + 56,574 + \alpha_1 - \alpha_2 \quad (\text{Equação 6})$$

$$RED_s = (1,0474 * BLUE_s) - 7,9222 + \beta_1 - \beta_2 \quad (\text{Equação 7})$$

$$NIR_s = (2,2791 * GREEN_s) + 2543,5 + \gamma_1 - \gamma_2 \quad (\text{Equação 8})$$

onde: BLUE<sub>s</sub>, GREEN<sub>s</sub>, RED<sub>s</sub> e NIR<sub>s</sub> – valores de reflectância simulados; AI – aleatorizações entre 0 e 1; AI<sub>1,5</sub> – aleatorizações entre 1 e 5;  $\alpha$  – aleatorização entre o menor e o maior valor de BLUE observada;  $\alpha_1$  e  $\alpha_2$  – aleatorizações entre 1 e o desvio padrão da GREEN observada;  $\beta_1$  e  $\beta_2$  – aleatorizações entre 1 e o desvio padrão da RED observada;  $\gamma_1$  e  $\gamma_2$  – aleatorizações entre 1 e o desvio padrão da NIR observada.

Os coeficientes observados nas equações 6 a 8 são coeficientes de regressões lineares entre seus respectivos valores observados, e foram utilizados para manter a consistência das simulações de GREEN, RED e NIR. A qualidade das simulações foi verificada graficamente pela sobreposição das relações entre os valores simulados e os observados para as diferentes variáveis. A consistência das estimativas de carbono obtidas com a RNA foi verificada pela análise gráfica dos valores de carbono preditos e observados em função das variáveis de entrada.

#### 2.2.4.2. Mapeamento do Estoque de Carbono

Após a definição das configurações da RNA e as respectivas variáveis de entrada foi feita a sua aplicação nos dados de toda a área, para gerar o mapa de predição do estoque de carbono. Primeiramente os objetos *raster* de cada variável espectral foram transformados para o formato *point*, em que cada pixel é convertido em um ponto com suas coordenadas centrais e os valores de reflectância. Em seguida, a tabela de atributos das *Shapefile* de pontos de cada variável espectral foi exportada com a ferramenta *Table to Excel* do ArcMap 10.4.1 ESRI®. As tabelas obtidas foram processadas, e geraram uma matriz única para aplicação da RNA selecionada. Uma vez estimados os valores de carbono, a matriz foi inserida no ArcMap 10.4.1 como uma *Shapefile* de pontos, transformada posteriormente para *raster*, com uso da ferramenta *point to raster*, resultando no mapa de distribuição do estoque de carbono estimado.

Foi obtido o somatório do estoque de carbono para toda a área, bem como a média do carbono estimado para cada pixel. A fim de comparar a consistência das estimativas, as estatísticas do estoque de carbono estimado nas parcelas amostrais foram obtidas com a ferramenta *Zonal Statistics to Table*. A Correlação de Pearson entre os valores médios do carbono estimado e os valores observados foi calculada.

### 3. RESULTADOS

#### 3.1. ESTRUTURA FLORESTAL

Foram inventariados 4.114 indivíduos, que totalizaram 4.579 fustes. A maioria dos indivíduos (1.515 - 36,83%) e de fustes (1.664 - 36,34%) foi observada no estrato intermediário, o qual não diferiu estatisticamente dos demais (Tabela 2). O menor e o maior número de indivíduos e de fustes por parcela foram observados no estrato inicial, e variaram de 53 a 278 e de 70 a 280, respectivamente (Figura 3). O estrato intermediário apresentou a menor variação nos valores para todos os indicadores estruturais e de estoque de carbono.

A medida máxima para *Ht* foi de 38,60 m, registrada no estrato avançado. O valor médio foi estatisticamente maior no estrato avançado, seguido do estrato inicial, o qual não diferiu estatisticamente do intermediário (Tabela 2). O maior *dap* foi de 102,50 cm, medido no estrato intermediário. O valor médio desta variável no estrato avançado foi maior, diferindo estatisticamente do intermediário. O *Dq* do estrato inicial foi o segundo maior e não apresentou

Tabela 2 – Estatística descritiva (média  $\pm$  desvio padrão) para as variáveis estruturais, número de fustes por hectare (Fustes), número de indivíduos por hectare (Ind.), altura total média (*Ht*), diâmetro quadrático (*Dq*) e área basal (AB) e de estoque de carbono, estoque individual médio (CI) e estoque total (CT) para as parcelas dos diferentes estratos sucessionais dos fragmentos florestais nativos da UFV Viçosa.

	Fustes	Ind.	<i>Ht</i> (m)	<i>Dq</i> (cm)	Área Basal (m <sup>2</sup> ha <sup>-1</sup> )	CI (Kg)	CT (Mg ha <sup>-1</sup> )
Estrato Inicial							
<b>Média</b>	1.428a	1.252a	9,74a	11,33ab	16,99a	20,42a	24,99a
<b>SX</b>	61,37	65,89	1,78	2,23	8,27	12,41	16,08
Estrato Intermediário							
<b>Média</b>	1.664a	1.515a	9,55a	10,68a	20,97ab	22,71a	35,79a
<b>SX</b>	13,21	18,61	0,83	0,89	3,11	14,26	14,87
Estrato Avançado							
<b>Média</b>	1.487a	1.347a	11,98b	12,91b	30,10b	62,57b	82,28b
<b>SX</b>	27,06	21,11	1,31	1,89	11,25	46,07	52,73
Total							
<b>Média</b>	152,63	137,13	10,42	11,64	2,15	35,24	47,68
<b>SX</b>	47,48	47,59	2,53	2,83	1,05	34,04	40,86
<b>Total</b>	4.579	4.114	–	–	64,55	–	143,05

SX – Desvio Padrão. Médias seguidas de letras iguais na mesma coluna não diferiram estatisticamente pelo teste de Tukey a 5% de probabilidade ( $\alpha \leq 0,05$ ).

diferença significativa dos demais estratos. Ambas as variáveis apresentaram maior amplitude de valores no estrato inicial (Figura 3).

A distribuição diamétrica dos indivíduos apresentou o padrão em J-invertido em todos os estratos. A classe de 5 a 10 cm correspondeu 59,42, 61,99 e 55,83% dos indivíduos dos estratos inicial, intermediário e avançado, respectivamente. O estágio intermediário obteve maior densidade de indivíduos nas duas primeiras classes (5 a 15 cm), sendo superado pelo estrato avançado nas classes seguintes (Figura 4).

Figura 3 – Número de indivíduos e de fustes, Ht média e  $Dq$ , e de estoque de carbono individual e por área nos diferentes estratos sucessionais dos fragmentos florestais nativos da UFV Viçosa.

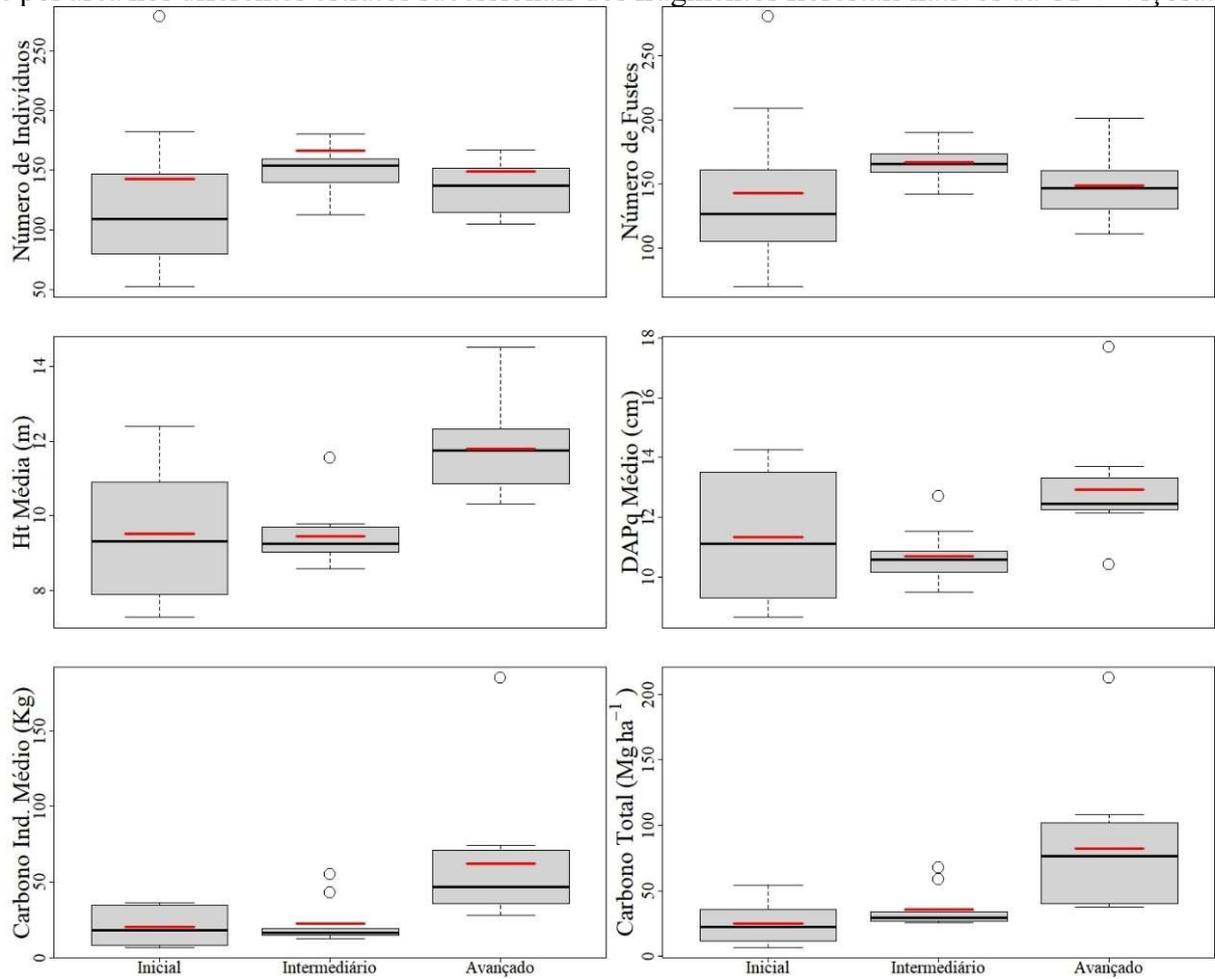
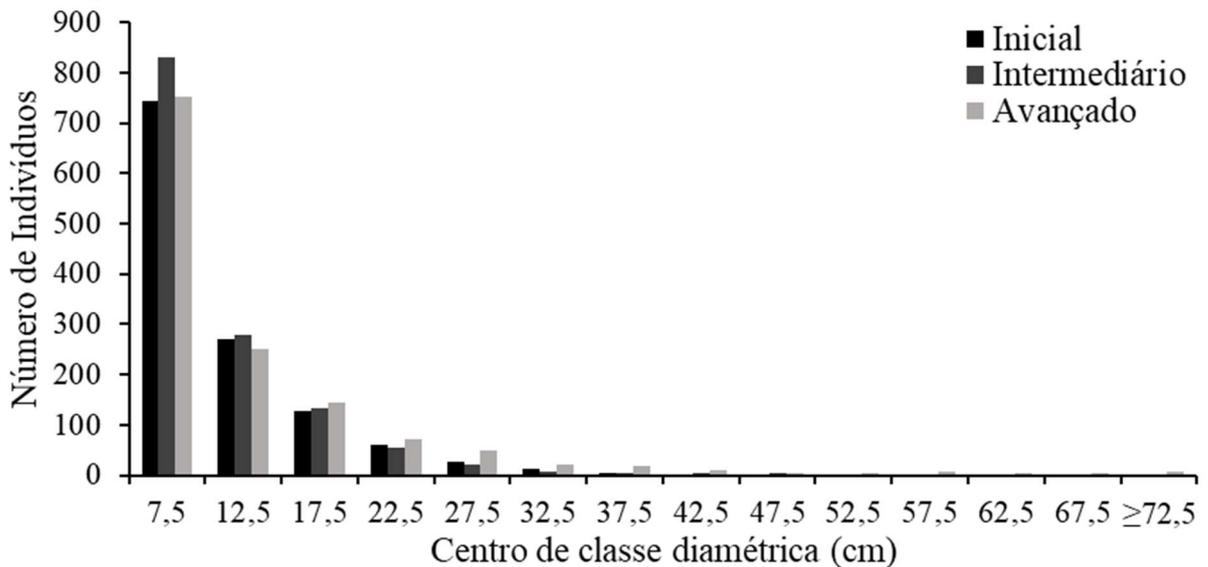
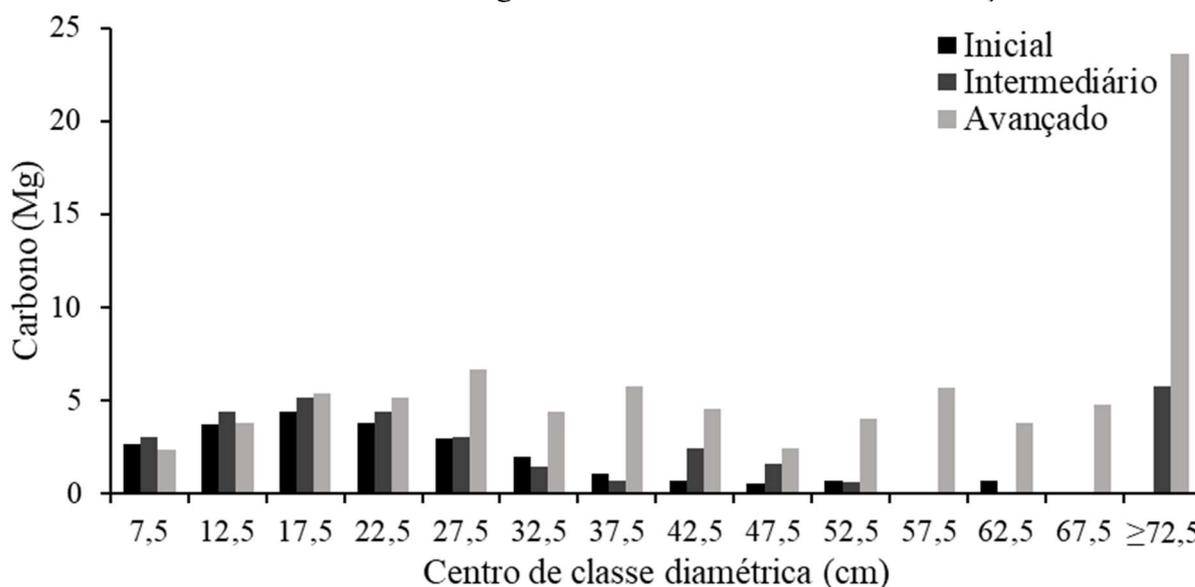


Figura 4 – Distribuição diamétrica dos indivíduos arbóreos nos diferentes estratos sucessionais dos fragmentos florestais nativos da UFV Viçosa.



Os valores de carbono individual variaram de 0,85 a 4.082,32 Kg ind<sup>-1</sup>, sendo a média entre todos os estratos igual a 35,24 Kg ind<sup>-1</sup>. O carbono total variou de 6,68 Mg ha<sup>-1</sup> (estrato inicial) a 212,65 Mg ha<sup>-1</sup> (estrato avançado), com média geral de 47,68 Mg ha<sup>-1</sup> (Tabela 2). Ambas as variáveis foram maiores no estrato avançado, sendo estatisticamente diferentes dos demais estratos. A maior amplitude registrada para os estoques de carbono individual e o total ocorreu no estrato avançado (Figura 3). As classes diamétricas de 5 a 25 cm contribuíram com os maiores estoques nos estratos inicial (14,52 Mg – 62,92%) e intermediário (16,90 Mg – 52,20%) (Figura 5). No estrato avançado os maiores estoques ocorreram nas classes acima de 25 cm. Indivíduos com diâmetro  $\geq 70$  cm representaram os maiores estoques nos estratos intermediário e avançado, 5,77 e 23,62 Mg (17,81 e 28,71%), respectivamente.

Figura 5 – Distribuição do estoque de carbono arbóreo em função da classe diamétrica, nos diferentes estratos sucessionais dos fragmentos florestais nativos da UFV Viçosa.



### 3.2. CORRELAÇÃO DAS VARIÁVEIS

As variáveis espectrais apresentaram maior correlação média com o estrato inicial (0,49), decrescendo nos estratos intermediário (0,28) e avançado (0,21) (Tabela 3). No período seco o EVI (*Enhanced Vegetation Index*) apresentou a maior correlação com o estoque de carbono do estrato inicial (0,58), enquanto a GREEN (Reflectância na banda verde) se correlacionou melhor com o estoque do estrato intermediário (-0,55) e com todos os estratos reunidos (-0,58); no estrato avançado as maiores correlações foram com a NIR (Reflectância

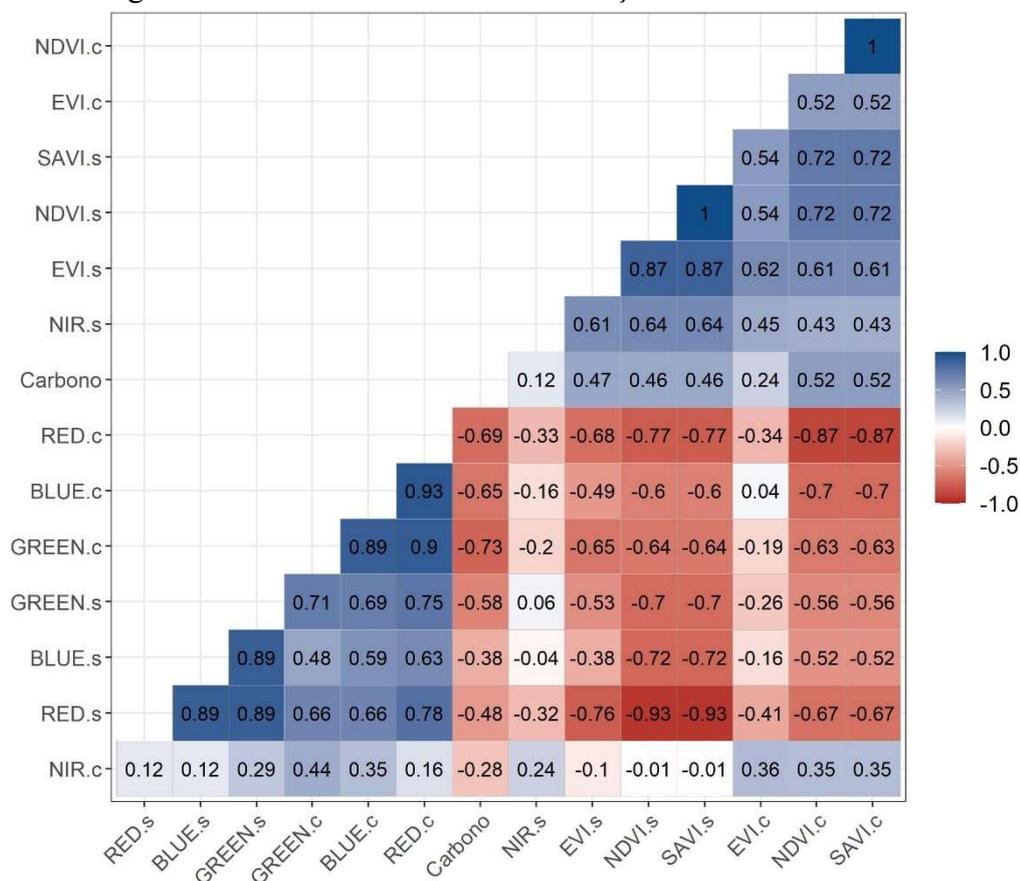
na banda infravermelho próximo) (-0,32). Para o período chuvoso o estoque do estrato inicial apresentou maior correlação com a RED (Reflectância na banda vermelho) (-0,58) e com o NDVI (*Normalized Difference Vegetation Index*) e SAVI (*Soil Adjusted Vegetation Index*) (0,58); no estrato intermediário o maior valor foi com o EVI (0,58), no avançado com NIR (0,52), e para todos os estratos associados a GREEN apresentou a maior correlação (-0,73) (Figura 6). A correlação média com todos os estratos foi maior para o período chuvoso (0,54). As reflectâncias BLUE (Reflectância na banda azul), GREEN e RED apresentaram correlação negativa em todos os estratos em ambos os períodos, enquanto a NIR apresentou esse padrão apenas para os estratos intermediário e avançado no período seco.

Tabela 3 – Correlação de Pearson entre as variáveis espectrais e o estoque de carbono dos diferentes estratos sucessionais dos fragmentos florestais da UFV Viçosa.

Período	Variável	Correlação Variável X Carbono por Estrato			
		Inicial	Intermediário	Avançado	Total
Seco	BLUE	-0,20	-0,17	-0,20	-0,38
	GREEN	-0,30	-0,55	-0,24	-0,58
	RED	-0,41	-0,22	-0,16	-0,48
	NIR	0,55	-0,31	-0,32	0,12
	EVI	0,58	0,15	-0,11	0,47
	NDVI	0,52	-0,13	0,10	0,46
	SAVI	0,52	-0,13	0,10	0,46
Chuvoso	BLUE	-0,50	-0,07	-0,26	-0,65
	GREEN	-0,56	-0,46	-0,47	-0,73
	RED	-0,58	-0,45	-0,31	-0,69
	NIR	0,52	0,06	0,52	-0,28
	EVI	0,48	0,58	-0,00	0,24
	NDVI	0,58	0,32	0,45	0,52
	SAVI	0,58	0,32	0,46	0,52
Média Seco		0,44	0,24	0,16	0,18
Média Chuvoso		0,54	0,32	0,27	0,35
Média total		0,49	0,28	0,21	0,26
Desvio Padrão total		0,11	0,17	0,07	0,16

Os valores de NDVI e SAVI apresentaram correlação perfeita dentro de cada período de análise (Figura 6). As variáveis de maior correlação com o estoque de carbono (BLUE, GREEN e RED do período chuvoso), apresentaram alta correlação entre si, com destaque para BLUE e RED ( $R=0,93$ ). A correlação com o estoque de carbono não foi significativa ( $p>0,05$ ) apenas para a NIR de ambos os períodos e para o EVI do período chuvoso.

Figura 6 – Matriz de correlação entre as reflectâncias e os Índices de Vegetação dos períodos chuvoso (c) e seco (s), e estoque de carbono arbóreo observado nos diferentes estratos sucessionais dos fragmentos florestais nativos da UFV Viçosa.



### 3.3. REDES NEURAIS ARTIFICIAIS

#### 3.3.1. Treinamento

Em geral as variáveis do período chuvoso apresentaram as melhores correlações com o estoque de carbono, devido ao aumento da reflectância provocado pelo incremento de área foliar no dossel (Tabela 3 e Figura 6). Assim, foram testadas RNA com 15 combinações de variáveis deste período. As RNA treinadas com todas as variáveis, sem o NDVI, e omitindo o SAVI e o NDVI apresentaram os melhores desempenhos ( $R \geq 0,9820$ ;  $RMSE \leq 5,0 \text{ Mg ha}^{-1}$  e  $Bias \leq \pm 0,13$ ) (Tabela 4). O teste L&O (LEITE e OLIVEIRA, 2002) demonstrou que a diferença entre o carbono observado e o estimado não foi estatisticamente significativa para nenhuma das RNA treinadas.

Dentre as RNA treinadas 73,33% (11) apresentaram tendência de subestimação (*Bias* negativo) (Tabela 4). Houve uma tendência em superestimar menores valores de estoque de

carbono, enquanto os maiores foram subestimados (Figuras 7 e 8). O erro relativo entre todas as combinações de variáveis testadas variou de -45,85% a 160,05% (Figura 8).

Tabela 4 – Desempenho estatístico das RNA com uso de diferentes combinações de variáveis espectrais do período chuvoso para estimar o estoque de carbono nos fragmentos florestais nativos da UFV Viçosa.

<b>Variável</b>	<b>R</b>	<b>RMSE</b>	<b>Bias</b>
- EVI	0,9630	6,9911	-0,1918
- NDVI	0,9871	4,1696	-0,1222
- SAVI	0,9807	5,0236	0,1757
- NIR	0,9687	6,4411	-0,1538
- EVI e NDVI	0,9763	5,6053	-0,1280
- EVI e SAVI	0,9706	6,2320	-0,1673
- EVI e NIR	0,9711	6,1697	-0,1029
- NDVI e NIR	0,9699	6,3182	-0,2875
- SAVI e NDVI	0,9821	4,9345	0,0065
- SAVI e NIR	0,9806	5,0861	-0,1060
- Ivs	0,9622	7,1168	-0,0670
- Ivs e NIR	0,9512	8,0552	-0,1411
- BLUE, GREEN e RED	0,9280	9,5606	0,0192
- Reflectâncias	0,9045	11,0913	-0,6053
Todas as Variáveis	0,9821	4,9019	0,0212

Figura 7 – Estoque de carbono estimado pelas RNA treinadas com diferentes combinações de variáveis espectrais do período chuvoso em função do estoque observado nos diferentes estratos sucessionais dos fragmentos florestais da UFV Viçosa.

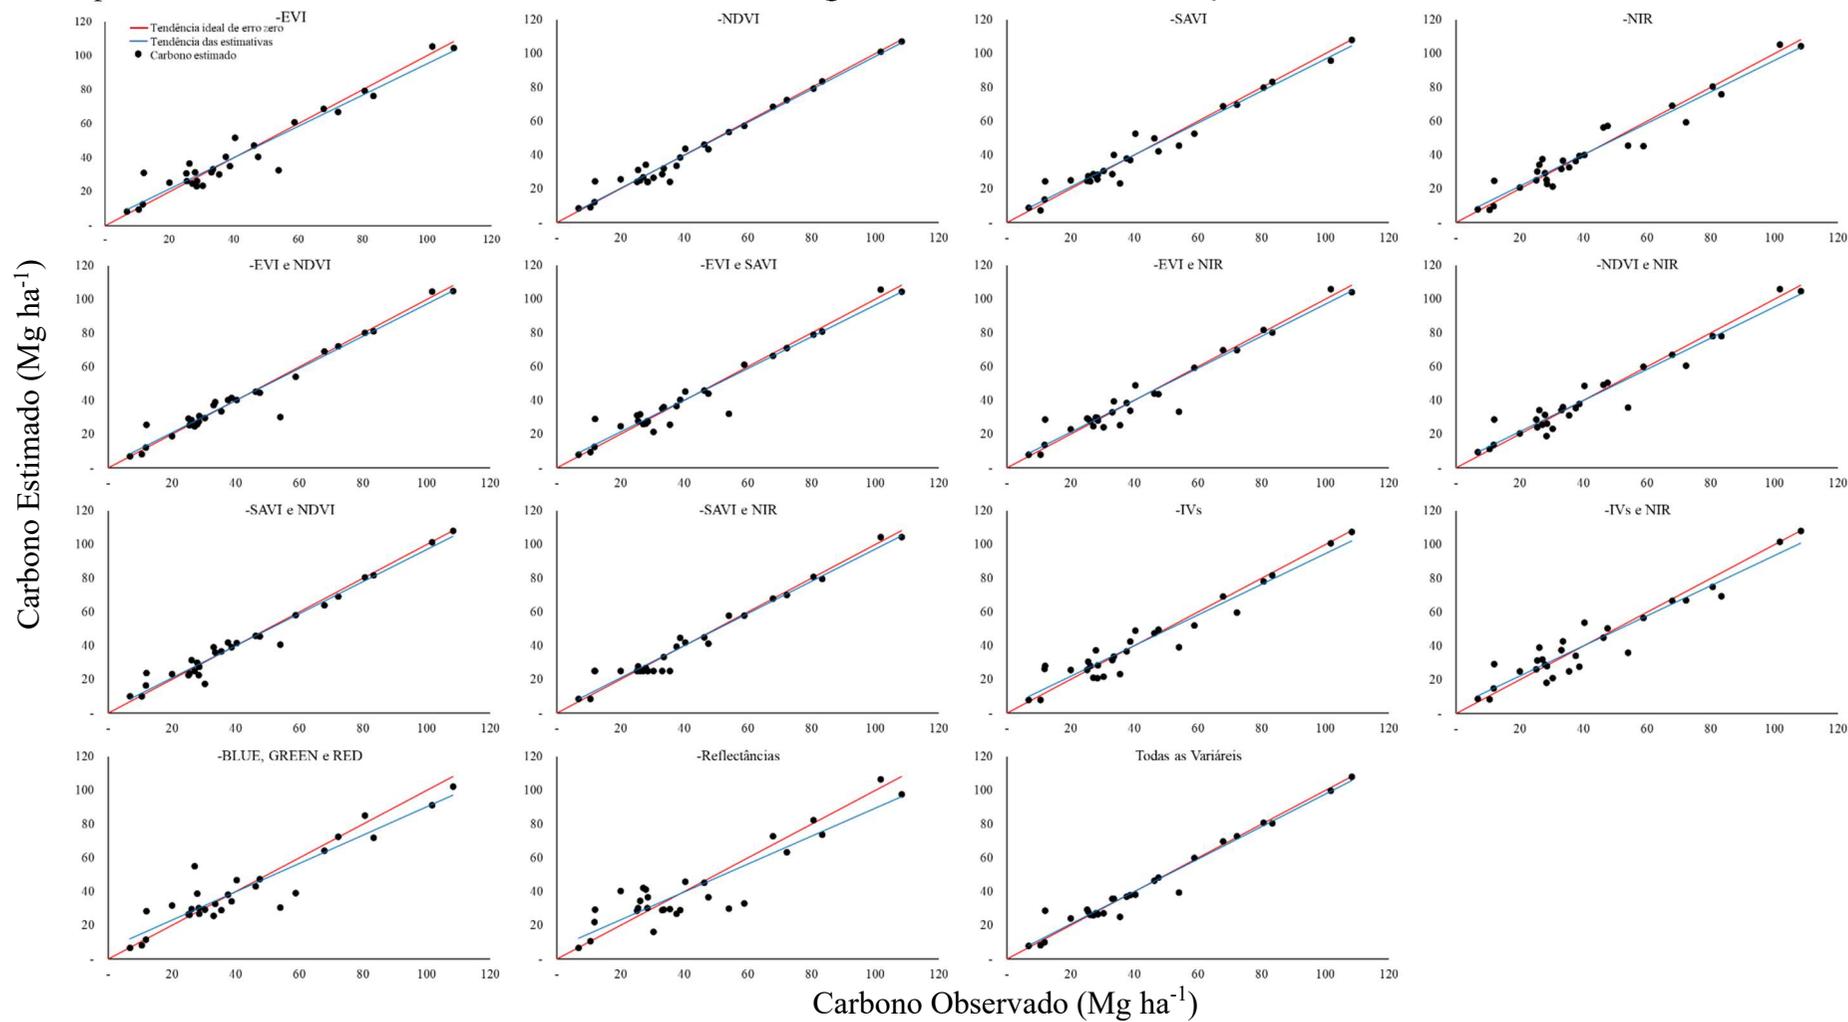
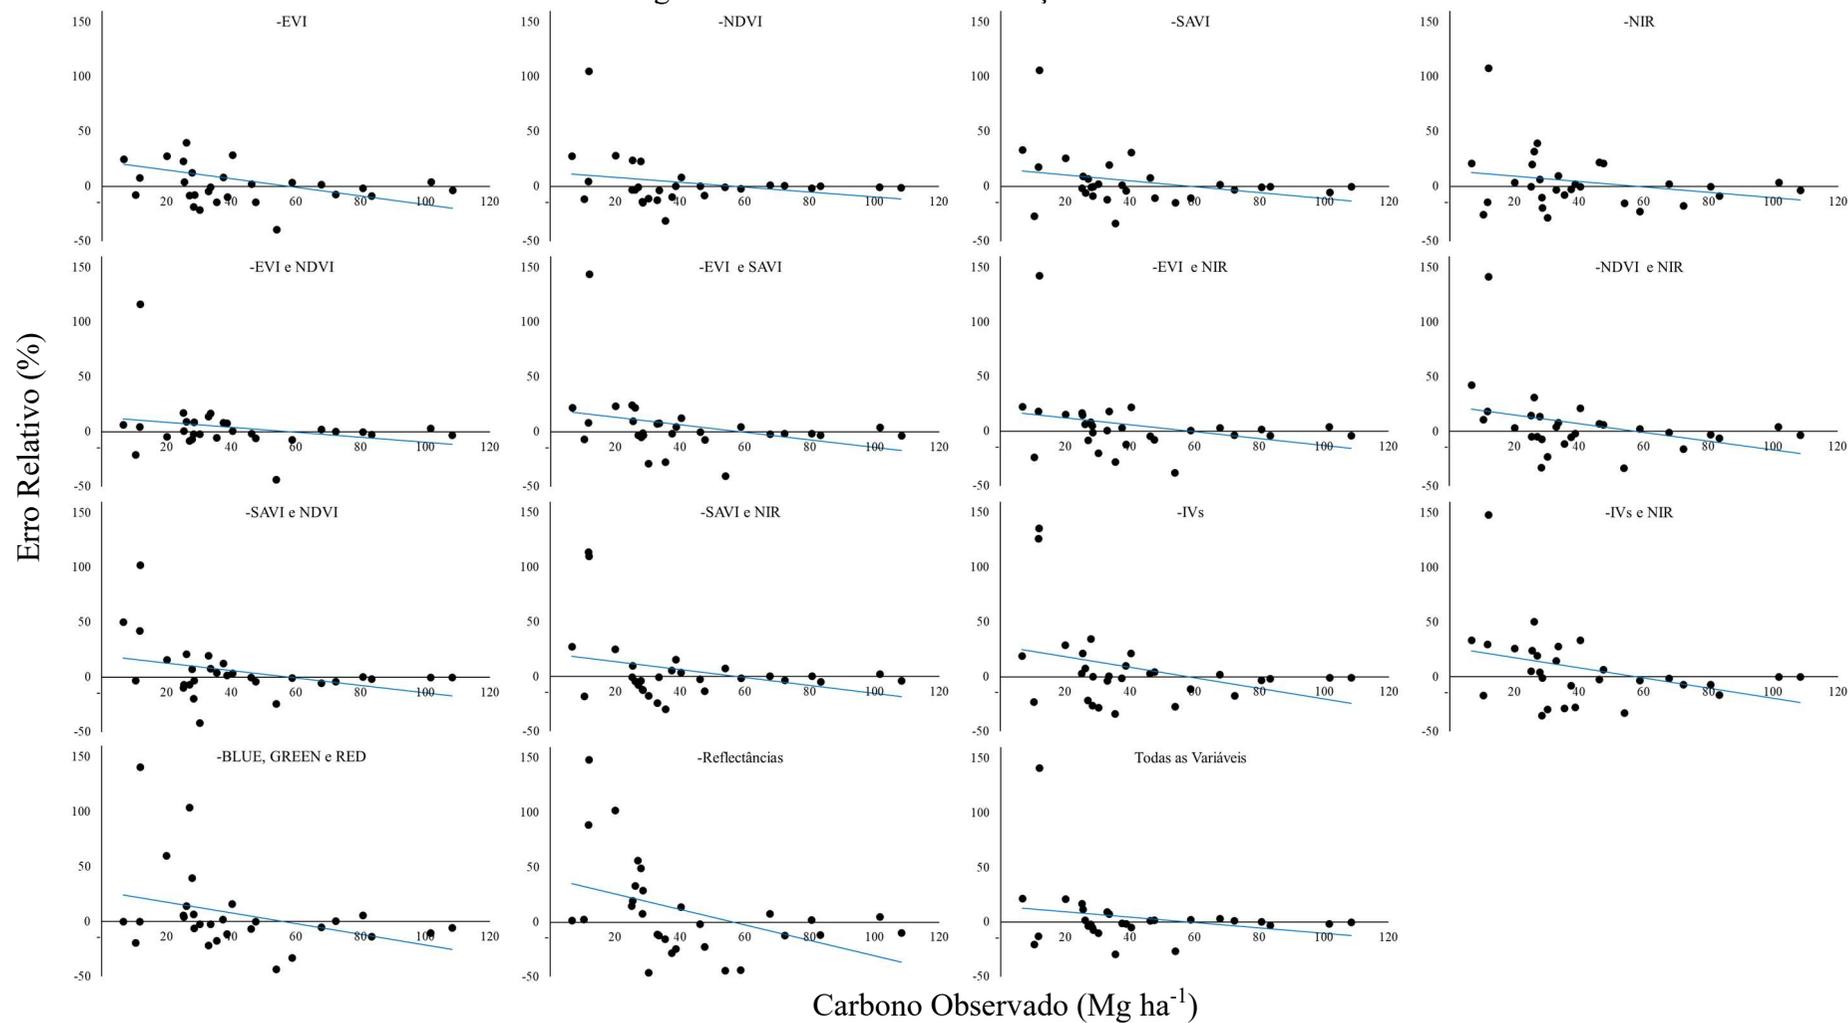


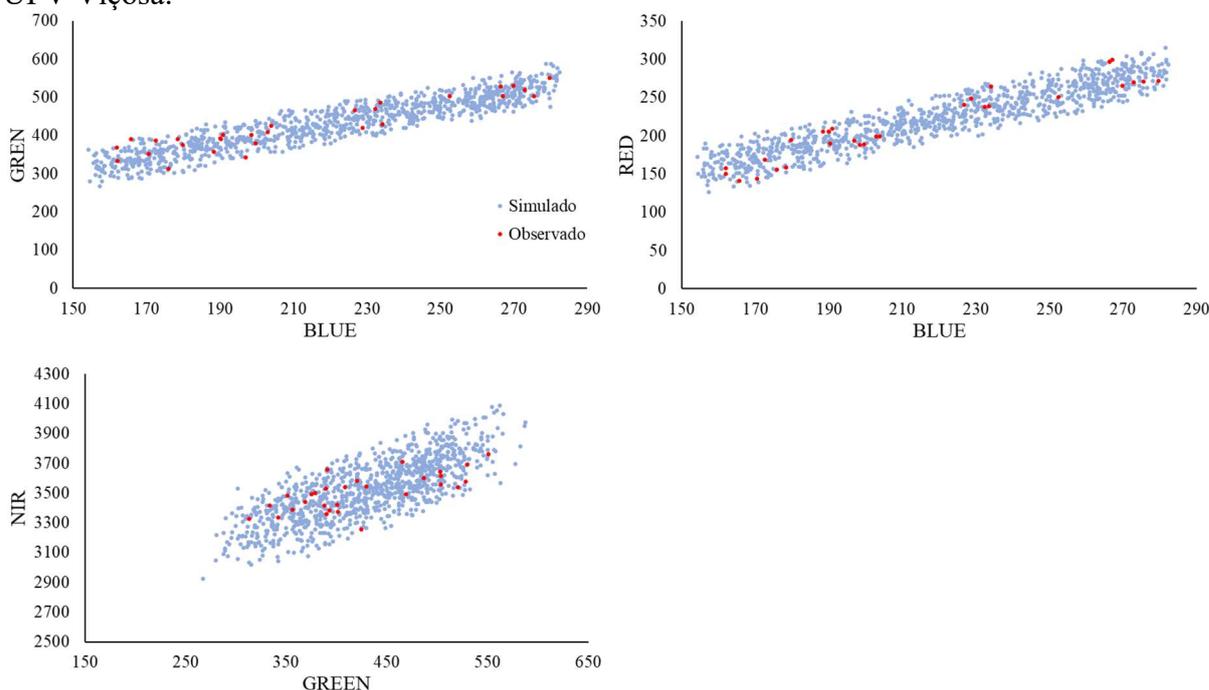
Figura 8 – Erro relativo das estimativas de carbono obtidas no treinamento das RNA com diferentes combinações de variáveis espectrais do período chuvoso nos diferentes estratos sucessionais dos fragmentos florestais da UFV Viçosa.



### 3.3.2. Validação

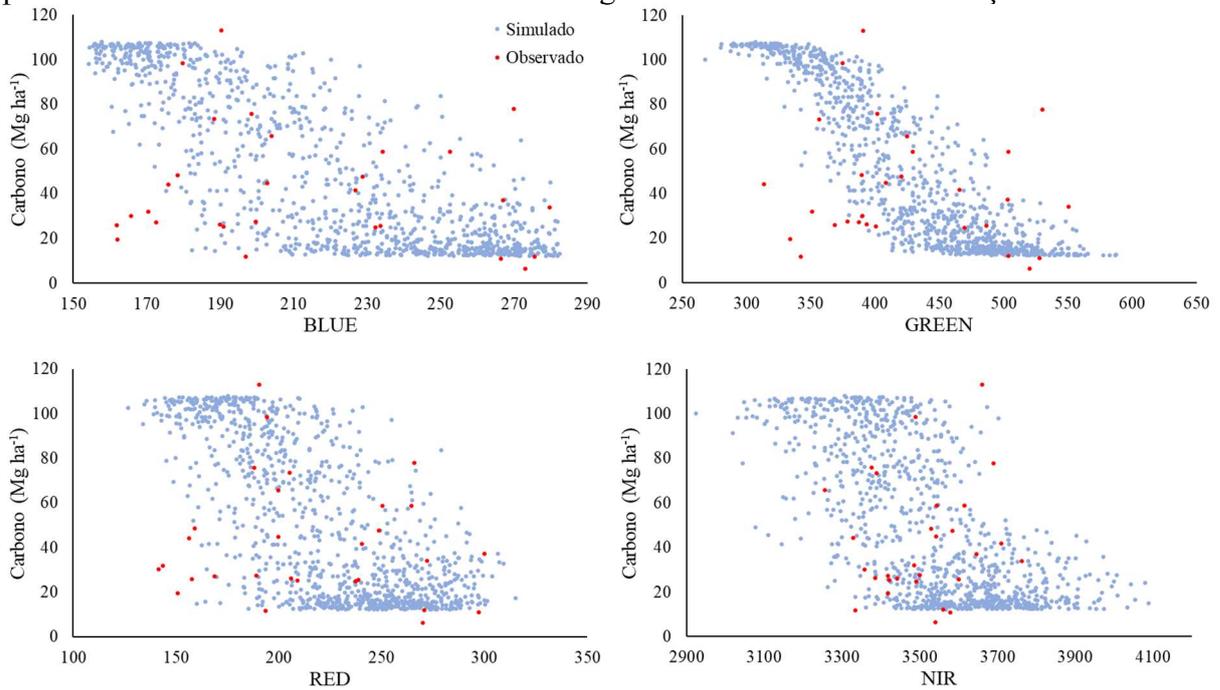
Os dados espectrais simulados com base nas relações lineares entre os dados Sentinel-2 para o período chuvoso foram consistentes, como pode ser observado pela sobreposição dos mesmos (Figura 9).

Figura 9 – Consistência dos dados de reflectância simulados com base nas reflectâncias do período chuvoso obtidas para os diferentes estratos sucessionais dos fragmentos florestais da UFV Viçosa.



Os indicadores de desempenho e o teste L&O (LEITE e OLIVEIRA, 2002), que demonstrou não haver diferença estatística entre as estimativas obtidas no treinamento, apontam para a possibilidade de uso das RNA com diferentes combinações de variáveis. A fim de reduzir o custo metodológico, foi selecionada a RNA que utilizava como variáveis de entrada apenas as reflectâncias do período chuvoso, cujas características e pesos podem ser observados no Apêndice A. A aplicação desta RNA nos dados simulados demonstrou sua capacidade de generalização, em que a relação entre os valores de carbono estimados pelos dados simulados foi compatível com a relação entre o carbono e variáveis observados (Figura 10).

Figura 10 – Consistência das estimativas do estoque de carbono arbóreo em função das reflectâncias do período chuvoso, obtidas pela RNA treinada com estas variáveis de entrada, para os diferentes estratos sucessionais dos fragmentos florestais da UFV Viçosa.



#### 3.4. MAPEAMENTO DO ESTOQUE DE CARBONO

A área total de floresta em diferentes estágios sucessionais na UFV Viçosa é de 861,66 ha. O estoque total de carbono nesta área, obtido pela modelagem da RNA com entrada das reflectâncias do período chuvoso, foi de 41.962,15 Mg. Os valores variaram de 6,68 a 108,29 Mg ha<sup>-1</sup> (Figura 11). A média foi de 48,70 Mg ha<sup>-1</sup>, e o desvio padrão igual a 34,79 Mg ha<sup>-1</sup>. A tendência de superestimação de menores valores e de subestimação em maiores valores de carbono também foi verificada na modelagem do estoque dos fragmentos (Figura 12). A correlação entre as médias do estoque de carbono estimado em cada parcela e o estoque observado foi de 0,84.

Figura 11 – Mapa de predição do estoque de carbono arbóreo, obtido pela RNA com as refletâncias do período chuvoso como variáveis de entrada, para os diferentes estratos sucessionais dos fragmentos florestais da UFV Viçosa.

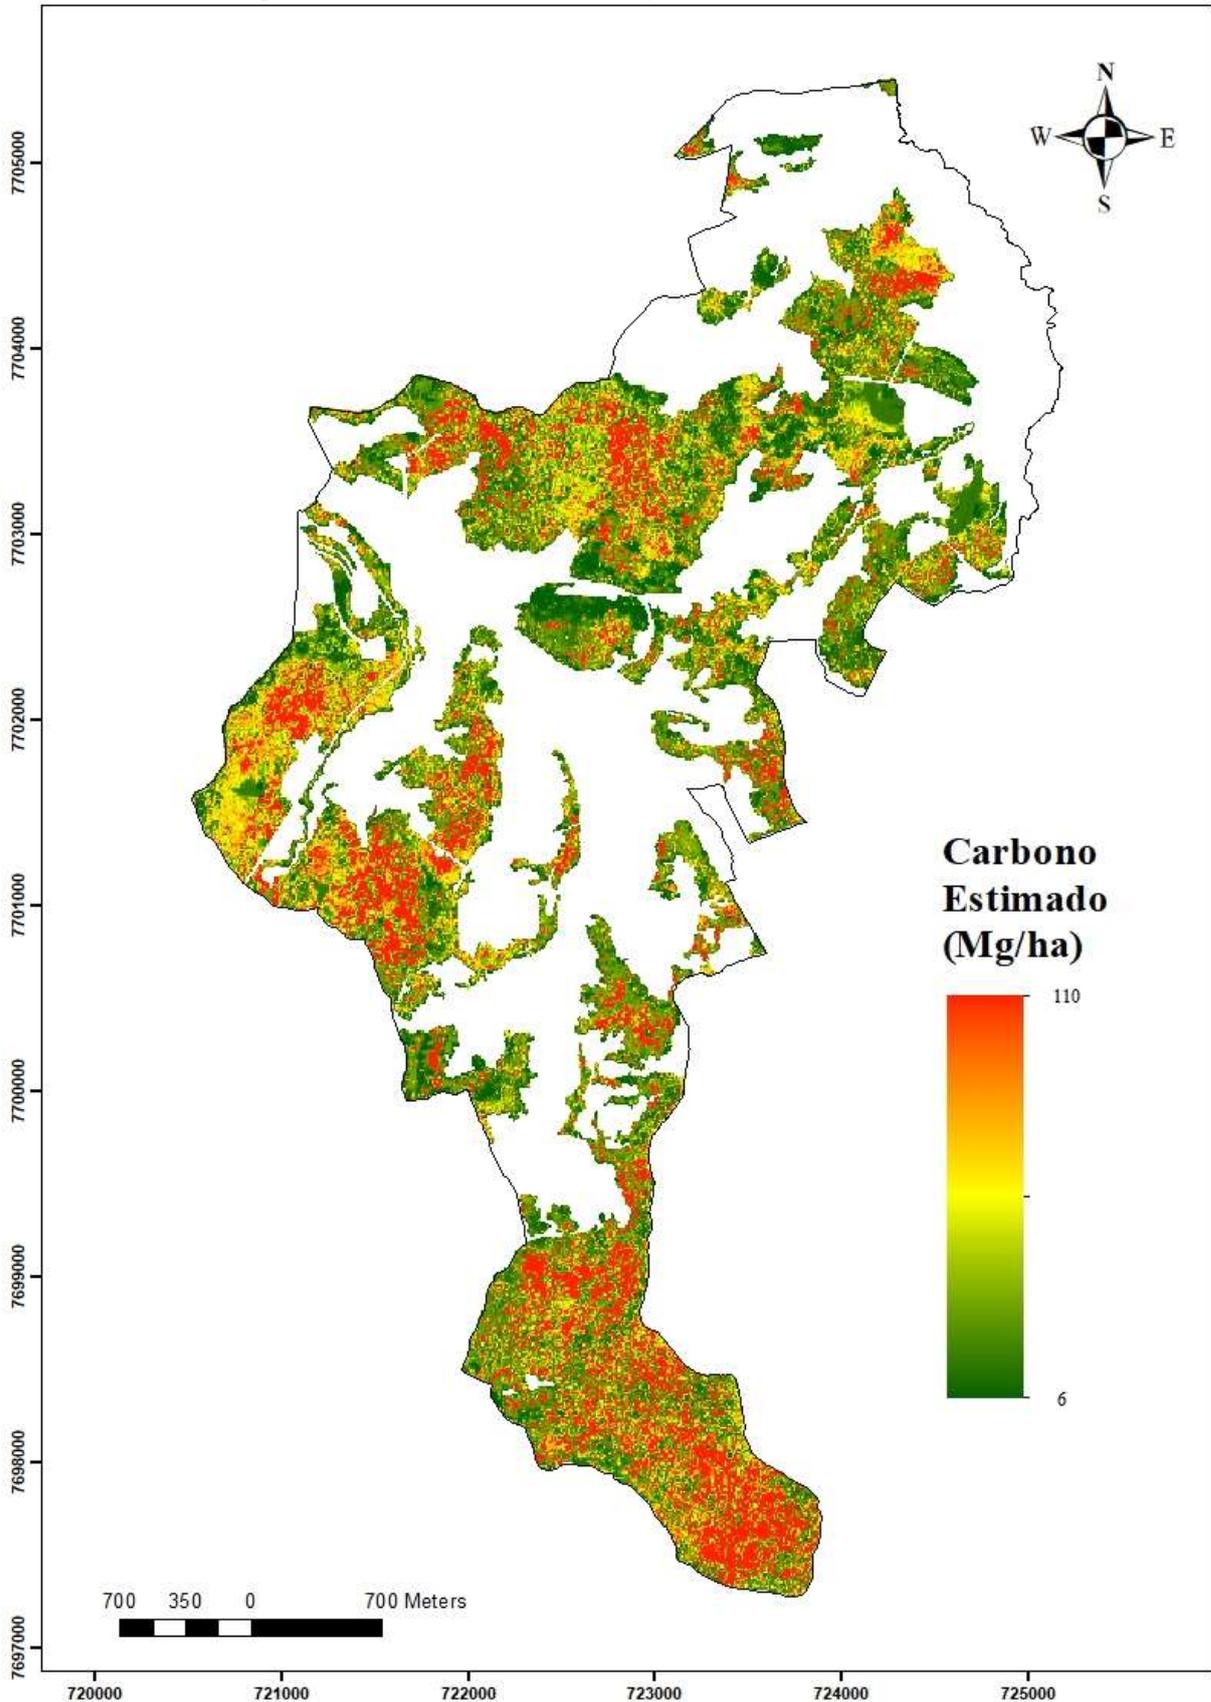
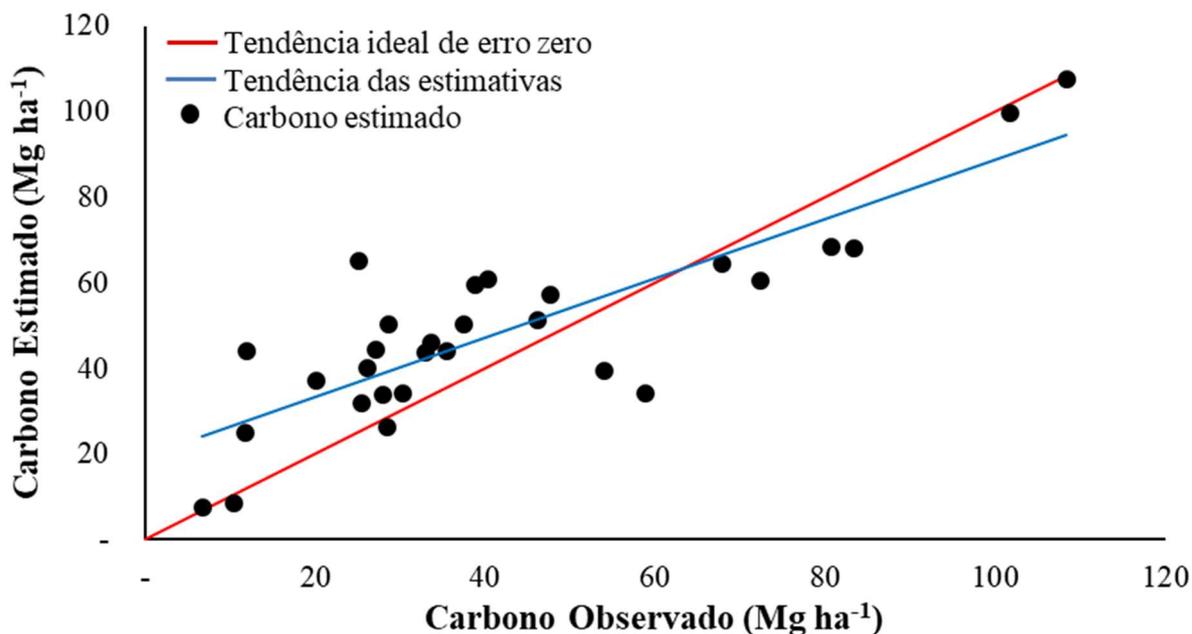


Figura 12 – Média do estoque de carbono por parcela estimado pela RNA treinada com as reflectâncias do período chuvoso, em função do estoque observado nos diferentes estratos sucessionais dos fragmentos florestais da UFV Viçosa.



## 4. DISCUSSÃO

### 4.1. ESTRUTURA FLORESTAL

A densidade foi de 1.428, 1.664 e 1.487 indivíduos ha<sup>-1</sup> para os estratos inicial, intermediário e avançado, respectivamente, não havendo diferença estatística (Tabela 2). Entretanto, os valores de densidade encontrados na Mata Atlântica são consideravelmente variáveis. Em um fragmento de Floresta Estacional Semidecidual Montana na região de Guanhães, Gaspar et al. (2014) levantaram uma densidade de árvores com  $dap \geq 5,0$  cm igual a 1.339 ind ha<sup>-1</sup>. A partir do mesmo critério de inclusão, Barbosa et al. (2014) observaram na Floresta Ombrófila Densa em São Paulo uma média de 2.084 ind ha<sup>-1</sup> para amostras em estágio inicial de sucessão, enquanto que nas áreas de vegetação secundária avançada inventariaram 2.185 ind ha<sup>-1</sup>. No município de Viçosa foram registrados valores de densidade variando de 1.020 a 2.440 ind ha<sup>-1</sup> (média = 1.802 ind ha<sup>-1</sup>) em um fragmento de Floresta Estacional Semidecidual Montana com 30 anos de sucessão secundária (RIBEIRO et al., 2010). Em uma área anexa, com cerca de 100 anos de sucessão, os valores de variaram entre 1.120 e 2.720 ind ha<sup>-1</sup> (média = 1.920 ind ha<sup>-1</sup>) (RIBEIRO et al., 2009).

Na UFV Viçosa, Sevilha et al. (2001) inventariaram 1.639 indivíduos arbóreos e arbustivos em uma amostra de 1 ha na Mata da Biologia, fragmento classificado por Peloso (2012) como estágio médio-avançado de sucessão secundária. Braga, Borges, Martins (2011) observaram uma densidade de 1.760 ind ha<sup>-1</sup> para uma área em estágio inicial, e de 1.520 ind ha<sup>-1</sup> para amostragem em vegetação em estágio avançado, ambas na Mata da Agronomia. Este resultado diverge do observado neste estudo, em que o estrato inicial obteve o menor número de indivíduos. Caliman et al. (2020) verificaram um aumento na densidade de 1.613 para 1.875 ind ha<sup>-1</sup> em um intervalo de 24 anos na Mata do Paraíso, um fragmento de cerca de 194 ha em estágio avançado de sucessão. Na Mata da Biologia, Peloso (2012) avaliou a dinâmica sucessional em dois locais durante 27 e 18 anos, e observou um padrão semelhante, com variação de 1.671 a 1.958 e 1.324 a 1.415 ind ha<sup>-1</sup>, respectivamente. O autor detectou que a densidade nos ambientes analisados apresentou crescimento até um certo ponto, seguido de uma diminuição significativa do número de indivíduos. Esta informação reafirma o perfil observado neste estudo, em que o estrato avançado apresentou densidade inferior ao estágio intermediário.

A partir da amplitude nos valores de densidade observada neste e em outros estudos, é evidente a relação com o avanço da sucessão secundária, demonstrada pela tendência de aumento no número de indivíduos. Entretanto, outros fatores como topografia e condições edáficas são citados como reguladores da densidade de indivíduos (CALIMAN et al., 2020). Eventos climáticos, como períodos de estiagem foram relacionados ao aumento das taxas de mortalidade na Mata Atlântica (ROCHA et al., 2020) e na Amazônia (PHILLIPS et al., 2009), também podem contribuir para mortalidade e influenciar negativamente o ingresso de árvores na floresta, o que promove oscilações na densidade de indivíduos.

Poucos estudos realizados sobre a estrutura do componente arbóreo dos fragmentos de vegetação da UFV Viçosa apresentam o número de fustes levantados. Amaro et al. (2013) inventariaram 1.510 fustes ha<sup>-1</sup> de espécies arbóreas e palmeiras na Mata da Silvicultura (estrato avançado), valor ligeiramente superior ao encontrado para o mesmo fragmento neste estudo (Tabela 2). A densidade de fustes observada nos diferentes estratos é compatível com intervalo apresentado por Lutz et al. (2018) para florestas tropicais e extratropicais. Segundo os autores, este é um componente estrutural com alta variação globalmente, com maiores valores nos ambientes tropicais. O padrão de aumento da densidade de indivíduos e de fustes não apresentou correlação expressiva ( $R < \pm 0,004$ ) com a evolução do estoque de carbono nos diferentes estratos. Esta observação é sustentada por Lutz et al. (2018), que constataram baixa

correlação entre a densidade geral de indivíduos e a biomassa, enquanto o número de árvores de maiores diâmetros influenciou o estoque correspondente.

A Ht média na região de Viçosa variou de 6,1 m em um fragmento de Floresta Estacional Semidecidual Montana de 30 anos de sucessão secundária (RIBEIRO et al., 2010) para 19,4 m em uma área adjacente com cerca de 100 anos (RIBEIRO et al., 2009). Ao analisar a dinâmica sucessional da Mata da Biologia (estágio médio-avançado), Peloso (2012) observou aumento da Ht média de 7,5 para 11,4 m, em um intervalo de 18 anos. Esta variação demonstra a evolução sucessional da floresta, e corrobora o intervalo de valores observados neste levantamento. Outros estudos também observaram valores de Ht médios similares, como Amaro et al. (2013), com 11,2 m para a Mata da Silvicultura. A Ht média ligeiramente superior para o estrato inicial, em relação ao intermediário, pode ser atribuída à amostragem de áreas de pastagens abandonadas, em que a maioria dos indivíduos foram árvores de grande porte, remanescentes do período de utilização da área.

No estudo de dinâmica sucessional de Peloso (2012), o  $Dq$  variou de 14,0 a 17,6 cm ao longo de 27 anos de observação. Estes valores são consonantes ao observado neste estudo para o estrato avançado, e superiores ao encontrado para os estratos inicial e intermediário. O autor também observou que, com o amadurecimento da floresta, há um aumento no  $Dq$  e no número de indivíduos com maiores  $dap$ , o que reforça o resultado alcançado nesta pesquisa. O  $Dq$  do estrato inicial foi ligeiramente maior que o obtido para o estrato intermediário (Tabela 2), o que pode ser explicado pelas diferentes feições florestais admitidas como formações iniciais, as quais variaram de capoeiras de pequeno porte até pastagens abandonadas e com indivíduos de grande porte esparsamente distribuídos.

O perfil de J-invertido é característico de florestas tropicais (LEAK, 2002), e foi verificado em diferentes estudos na região de Viçosa (RIBEIRO et al., 2009; 2010) e nos fragmentos florestais da UFV Viçosa (PELOSO 2012; CALIMAN et al., 2020). A presença deste padrão em todos os estratos sucessionais deste estudo evidencia que os fragmentos, independentemente do estágio de sucessão, apresentam capacidade de regeneração da comunidade arbórea (SILVA-JÚNIOR, 2005; BUENO et al., 2013; WATZLAWICK et al., 2013). Não foram observadas variações entre os estratos, porém, em uma análise a nível de parcela é possível que diferenças no perfil da distribuição diamétrica possam ser encontradas. Segundo Caliman et al. (2020), a distribuição diamétrica de uma floresta pode apresentar variações ocasionadas por condições de sítio, como topografia e características edáficas. O aumento do  $Dq$  e da densidade de indivíduos em classes diamétricas maiores, associados à

manutenção da distribuição em J-invertido, são fatores primordiais no aumento e permanência dos estoques de carbono arbóreo (PELOSO, 2012; BERENGUER et al., 2014; POORTER et al., 2015; LUTZ et al., 2018; BORDIN et al., 2021).

#### 4.2. ESTOQUE DE CARBONO

A maioria dos estudos realizados na Mata Atlântica abordam o inventário ou modelagem da biomassa e carbono aéreos, especialmente do componente arbóreo (CUNHA et al., 2009; TORRES et al., 2013; CASSOL; SALDANHA; KUPLICH, 2014; FERRAZ et al., 2014; SILVEIRA et al., 2021). Outros trabalhos contabilizaram a contribuição da regeneração e estrato herbáceo (FIORENTIN et al., 2015), e o estoque de carbono na biomassa subterrânea (LIMA et al., 2011), serrapilheira (CUNHA et al., 2009; TORRES et al., 2013) e necromassa lenhosa (VILLANOVA et al., 2019). O estoque nas formações florestais deste bioma são substanciais, com registros superiores a 165 Mg ha<sup>-1</sup> de carbono aéreo estocada no componente lenhoso sem casca (RIBEIRO et al., 2009).

O estoque de carbono obtido com o modelo de Schumacher e Hall ajustado por Amaro (2010) para os fustes com casca do estrato avançado foi estatisticamente superior aos demais. Os estoques de carbono nos estratos inicial e intermediário não foram estatisticamente diferentes, embora a média do estrato intermediário fosse maior (Tabela 2). As parcelas consideradas neste estudo como estrato avançado estão alocadas na Mata da Silvicultura, fragmento com mais de 80 anos em sucessão (MEIRA-NETO e MARTINS, 2003; ROCHA et al., 2020). A partir de dados coletados em 2010 nessas parcelas, e equações de Amaro (2010), Amaro et al. (2013) encontraram um estoque de carbono médio de 58,20 Mg ha<sup>-1</sup>, valor consideravelmente menor ao encontrado no presente estudo. Torres et al. (2013), com as mesmas equações, observaram uma média de 26,44 Mg ha<sup>-1</sup> para o estoque de carbono nos fustes com casca de um fragmento com 20 anos de sucessão no município de Viçosa. Ainda na região de Viçosa, o estoque de carbono do componente arbóreo (sem casca) variou de 19,50 Mg ha<sup>-1</sup> em um fragmento de Floresta Estacional Semidecidual Montana de 30 anos de sucessão secundária (RIBEIRO et al., 2010) para 83,34 Mg ha<sup>-1</sup> (com casca) em uma área adjacente com cerca de 100 anos (RIBEIRO et al., 2009). Rocha et al. (2020) observaram um incremento líquido significativo no estoque de carbono arbóreo da Mata da Silvicultura (↑25,52 Mg ha<sup>-1</sup>) em um período de 22 anos, aumentando de 57,70 Mg ha<sup>-1</sup> em 1994 para 75,87 Mg ha<sup>-1</sup> em 2016. Estes resultados demonstram o crescimento da retenção de carbono no compartimento arbóreo

aéreo durante o processo de sucessão ecológica (LU, 2005; MASEK e COLLATZ, 2006), o que evidencia a necessidade da restauração (GRASSI et al., 2017; MORAIS-JUNIOR et al., 2019) e proteção das florestas tropicais e subtropicais como sumidouros de carbono (BERENGUER et al., 2014; LIU et al., 2017; SULLIVAN et al., 2020; BORDIN et al., 2021).

Os valores de estoque de carbono aéreo nas florestas da região de Viçosa, MG, são altamente variáveis (AMARO et al., 2013; TORRES et al., 2013). Segundo Amaro et al. (2013), a estrutura interna desigual e complexa das florestas é um dos fatores que ocasiona a variação do estoque de carbono em vegetações de um mesmo estágio sucessional. Estes aspectos explicam os altos valores de desvio padrão encontrados para o estoque de carbono individual e por área, observados no estrato avançado (Tabela 2). Barbosa et al. (2014) observaram o mesmo padrão de heterogeneidade ao avaliarem a biomassa dos estágios inicial e avançado em áreas de Floresta Ombrófila Densa em São Paulo. Segundo Bordin et al. (2021), florestas estruturalmente complexas e mais maduras são responsáveis por manter o armazenamento de carbono por longos períodos de tempo. Os estratos inicial e intermediário apresentam baixa variação interna dos valores de carbono individual e por área (Tabela 2). Entretanto, o estrato inicial é ligeiramente mais heterogêneo, resultado das diferentes feições florestais admitidas como formações iniciais, como explicado anteriormente.

Árvores pertencentes a classes diamétricas maiores são responsáveis pela maior parte dos estoques de carbono em florestas maduras, e são especialmente influenciadas pelas pressões antropogênicas (LUTZ et al., 2018; BORDIN et al., 2021). Assim, a superioridade no estoque das classes de indivíduos  $\geq 20,0$  cm no estrato avançado (Figura 5) pode ser atribuída ao amadurecimento da floresta e à ausência de perturbações significativas. Berenguer et al. (2014) observaram o mesmo padrão em áreas com diferentes níveis de perturbação na Amazônia, em que florestas primárias apresentaram maior densidade de árvores de grande porte e maior estabilidade do estoque de carbono em relação às áreas com corte seletivo e incêndios de sub-bosque. Tais eventos antrópicos destrutivos são especialmente preocupantes, à medida que as florestas são degradadas e sua biomassa é queimada, por exemplo, os estoques de carbono se tornam atmosféricos novamente (LU, 2005; GIBBS et al., 2007; ANAYA; CHUVIECO; PALACIOS-ORUETA, 2009).

Além das variáveis estruturais, a diversidade de espécies em florestas tropicais também é um fator determinante na estocagem de biomassa e carbono (POORTER et al., 2015). Fatores climáticos como as variações anuais de temperatura (LIU et al., 2017; SULLIVAN et al., 2020; BORDIN et al., 2021) e a disponibilidade pluviométrica (PHILLIPS et al., 2009; POORTER et

al., 2016; LIU et al., 2017), também são reguladores dos estoques de biomassa e carbono aéreos. De acordo com Sullivan et al. (2020), florestas tropicais intactas podem manter seus estoques de carbono estáveis mesmo com aumentos significativos da temperatura. Neste contexto, a compreensão da relação entre os fatores estruturais e a disposição do carbono em florestas secundárias, como as analisadas neste estudo, é fundamental para prever os processos de estocagem e perda de carbono frente aos fenômenos adversos das mudanças climáticas antropogênicas (GÜNERALP; FILIPPI; RANDALL, 2014; BOUCHER et al., 2020; REX et al., 2020).

Na América do Sul, os estoques de biomassa e carbono encontrados na Mata Atlântica são superados apenas pelos observados na Amazônia (SULLIVAN et al., 2020; BORDIN et al., 2021), o que reafirma a necessidade de conservação dos remanescentes florestais destes biomas, como importantes sumidouros de carbono atmosférico. O estudo do carbono em diferentes regiões e condições florestais da Mata Atlântica contribui para a compreensão dos estoques globais, além da produção de estimativas em nível continental (AVITABILE et al., 2016; BORDIN et al., 2021). Nesta perspectiva, o mapeamento dos estoques tropicais de carbono florestal é crítico para compreensão do seu ciclo global e seus efeitos no clima (GIBBS et al., 2007; CLARK et al., 2011; SAATCHI et al., 2011; REX et al., 2020).

#### 4.3. VARIÁVEIS ESPECTRAIS E O ESTOQUE DE CARBONO

A correlação entre o estoque de carbono e as reflectâncias de diferentes bandas e os IVs variam entre os diferentes sensores passivos, como observado por Cassol, Saldanha, Kuplich (2014) em Floresta Ombrófila Mista. Os autores verificaram que para os sensores LISS-III/Resourcesat-1 (*Linear Imaging SelfScanner*) e TM (*Thematic Mapper*) as maiores correlações com o estoque de carbono foram obtidas com a NIR e com os IVs NDVI, SAVI e SR (*Simple Ratio Index*), sendo que para o sensor ASTER (*Advanced Spaceborne Thermal Emission and Reflection Radiometer*) houve altas correlações com a GREEN, corroborando os resultados deste estudo. As variações sazonais e estruturais do dossel da floresta podem provocar saturação espectral da reflectância (LU, 2006; CASTILLO-SANTIAGO; RICKER; JONG, 2011; ZHU e LIU, 2015). Neste contexto, a maior correlação entre as variáveis do período chuvoso e o estoque de carbono dos diferentes estratos (Tabela 3 e Figura 6) pode ser atribuída ao aumento da resposta espectral da floresta decorrente do aumento das chuvas (WANG; RICH; PRICE, 2003).

Vegetações muito exuberantes também podem ser uma fonte de saturação da reflectância, ocorrendo, principalmente, nas bandas RED e NIR, em valores de Índice de Área Foliar (IAF) acima de 3 e 7-8, respectivamente (GAUSMAN; RODRIGUEZ; RICHARDSON, 1976). O NDVI é um IV dependente dessas bandas e também sofre saturação em valores de IAF em torno de 3 (WANG et al., 2016; YANG et al., 2021). Estas situações diminuem a precisão das estimativas de biomassa e carbono aéreo (ANAYA; CHUVIECO; PALACIOS-ORUETA, 2009; ZOLKOS; GOETZ; DUBAYAH, 2013). Esta limitação pode ser, em alguns casos, superada com a aplicação de variáveis de textura, oriundas das próprias imagens (DOMINGUES et al., 2020). Os resultados deste estudo sustentam tal afirmação, uma vez que a correlação média entre as variáveis espectrais e o estoque de carbono foi inversamente relacionada com o avanço do estágio sucessional (Tabela 3), além da tendência das RNA em subestimar maiores valores de carbono (Figura 7 e 8), presentes no estrato avançado. Estes fatores tornam crítica a necessidade de estabelecer metodologias robustas de modelagem de carbono em florestas secundárias em estágio avançado de sucessão na Mata Atlântica, o que colabora para o desenvolvimento de práticas adequadas de manejo e conservação das florestas maduras e seus estoques de carbono (MOLINA et al., 2016).

Os Índices de Vegetação são dados derivados das reflectâncias, reportados na literatura como variáveis bem correlacionadas com o estoque de biomassa e carbono, e por isso são considerados preditores adequados, capazes de melhorar a acurácia das estimativas (CLARK et al., 2011; ZALD et al., 2016; LAURIN et al., 2017; ZHANG et al., 2019). Segundo Bollas, Kokinou, Polychronos (2021), o NDVI obtido de imagens satélite Sentinel-2 com pixel de 10 m possui qualidade equiparada ao obtido por sensores aerotransportados, e apontam para o potencial de aplicação destes dados na avaliação da vegetação. Adamu et al. (2021) observaram que diferentes IVs oriundos de Sentinel-2 foram bem correlacionados ( $R \geq 0,63$ ) com a biomassa urbana em região de Savana Tropical na Nigéria, e quando aplicados à Regressão Linear produziram estimativas satisfatórias. Esta tendência não foi corroborada pelos resultados deste estudo, em que os IVs apresentaram correlações semelhantes (período seco) ou inferiores (período chuvoso) às observadas entre as reflectâncias e o estoque de carbono (Tabela 3). Além disso, o teste L&O (LEITE e OLIVEIRA, 2002) demonstrou que a contribuição dos IVs no potencial preditivo das RNA foi irrisória (Tabela 4 e Figuras 7 e 8). Barbosa et al. (2014) também verificaram que a aplicação do NDVI e do EVI em Modelos Lineares Generalizados não melhoraram a acurácia das estimativas de biomassa em florestas secundárias de diferentes estágios sucessionais da Mata Atlântica.

Sothe et al. (2017) avaliaram a eficiência de reflectâncias, métricas de textura e IVs como variáveis de entrada para a classificação de estágios sucessionais em Floresta Ombrófila Mista (Mata Atlântica) no sul do Brasil. Os autores verificaram que as reflectâncias foram as variáveis mais importantes, quando empregadas em *Random Forest*, e que o acréscimo das demais variáveis não conferiu ganho preditivo. Em um estudo conduzido na Mata da Silvicultura (considerada estrato avançado neste estudo), Ferraz et al. (2014) aplicaram reflectâncias e IVs obtidos do satélite Ikonos como variáveis de entrada em RNA para modelagem da biomassa. Os autores observaram que o emprego dos IVs não representava ganhos significativos na precisão das estimativas. Os resultados deste estudo, corroborados por Ferraz et al. (2014) e Sothe et al. (2017), demonstram que a biomassa e carbono na Mata Atlântica da Zona da Mata mineira podem ser adequadamente modelados a partir da reflectância de diferentes sensores, reduzindo o gasto computacional na obtenção de variáveis derivadas.

A amplitude temporal e espacial dos sensores da série Landsat, por exemplo, permitiram que seus dados espectrais fossem largamente utilizados na modelagem da biomassa e do carbono florestais em uma escala de até 30 m (ANAYA; CHUVIECO; PALACIOS-ORUETA, 2009; LU et al., 2016; ZALD et al., 2016; ZHANG et al., 2019; NUNES et al.; 2020). O lançamento de novos satélites com sensores aprimorados, maior resolução espacial e temporal, aumenta a disponibilidade de dados, o que favorece a avaliação das florestas e permite a compreensão do estoque e da dinâmica do carbono em nível global (LAURIN et al., 2017). Neste trabalho foi proposto uma abordagem com resolução espacial de 10 m para estimativas de carbono. Foram utilizados dados de reflectância coletados pelo MSI (*MultiSpectral Instrument*), que foi lançado em 2015 e é um dos sensores de imageamento da superfície terrestre mais recentes (ESA, 2015).

A efetividade dos resultados apresentados neste e em outros estudos (SOTHE et al. 2017; ADAMU et al., 2021; BOLLAS; KOKINOU; POLYCHRONOS, 2021) demonstra a aplicabilidade dos dados de alta resolução do MSI na estimação dos estoques de carbono da Mata Atlântica, e conseqüentemente na obtenção de informações sobre a contribuição deste bioma no ciclo global do carbono. Novos estudos podem aprimorar as metodologias de modelagem do estoque de carbono na Mata Atlântica, a partir do uso de dados de sensores multiespectrais suborbitais, os quais são indicados para análise de áreas menos extensas (BOLLAS; KOKINOU; POLYCHRONOS, 2021). Além disso, a inclusão de variáveis biofísicas ambientais no processo de modelagem também pode aumentar a acurácia das

estimativas (LU, 2005; MASEK e COLLATZ, 2006; POWELL et al., 2010; CASTILLO-SANTIAGO; RICKER; JONG, 2011; BRANDT et al., 2012; GÜNERALP; FILIPPI; RANDALL, 2014; SILVEIRA et al., 2021).

#### 4.4. MODELAGEM DO ESTOQUE DE CARBONO

Equações alométricas baseadas em variáveis dendrométricas foram aplicadas com sucesso para predição de biomassa e carbono em diferentes compartimentos florestais da Mata Atlântica, tanto em nível de povoamento como de indivíduo (CUNHA et al., 2009; FIORENTIN et al., 2015; ALMEIDA et al., 2020). Em relação às técnicas que empregam tecnologias de sensoriamento remoto, estudos com dados de sensores multiespectrais são os mais recorrentes, com emprego de reflectância de diferentes bandas, além de Índices de Vegetação (WATZLAWICK; KIRCHNER; SANQUETTA, 2009; BARBOSA et al., 2014; CASSOL; SALDANHA; KUPLICH, 2014; FERRAZ et al., 2014; SILVEIRA et al., 2021). O uso de sensores ativos também é registrado na literatura (ALMEIDA et al., 2020). A integração de dados passivos e ativos, como radar de abertura sintética e LiDAR, podem aumentar a acurácia da estimativa de componentes biofísicos em florestas tropicais (ZOLKOS; GOETZ; DUBAYAH, 2013; LAURIN et al., 2014; DOMINGUES et al., 2020).

Dados de sensoriamento remoto têm sido utilizados em diferentes metodologias para modelagem da biomassa e carbono da Mata Atlântica. Dentre métodos paramétricos destaca-se o uso dos Modelos Lineares Generalizados (BARBOSA et al., 2014), Regressão Linear Simples (CASSOL; SALDANHA; KUPLICH, 2014; FERRAZ et al., 2014; FIORENTIN et al., 2015) e Regressão por Mínimos Quadrados Ponderados (ALMEIDA et al., 2020). Modelos regressores apresentam bom desempenho quando são ajustados com base em um conjunto de dados representativo, em situações onde a relação entre as variáveis é bem conhecida e a separação de dados para validação é desnecessária. No presente estudo foram testadas a regressões Linear e Exponencial, as quais não apresentaram resultados promissores (resultados não apresentados) devido ao pequeno número de dados para ajuste e à relação pouco evidente entre as variáveis espectrais e o estoque de carbono.

Dentre os métodos não-paramétricos as RNA (FERRAZ et al., 2014) e o *Randon Forest* (SILVEIRA et al., 2021) foram aplicados para estimar o estoque de biomassa e carbono na Mata Atlântica. RNA do tipo MPL relacionam as variáveis de saída com as variáveis de entrada sem o estabelecimento de um modelo matemático, sendo amplamente aplicadas na estimação

de variáveis biofísicas florestais a partir de sensoriamento remoto (DOMINGUES et al., 2020). Esta metodologia de modelagem possui desempenho significativamente superior a métodos paramétricos (ZHANG et al., 2019; DOMINGUES et al., 2020). Entretanto, há certo risco de memorização dos dados de entrada. Neste caso, a validação é fundamental para verificar a capacidade de generalização da RNA treinada.

As RNA treinadas a partir de dados Sentinel-2 apresentaram desempenho satisfatório para modelagem do estoque de carbono, com alta correlação entre os valores observados e preditos, baixos RMSE e *Bias* próximos de zero (Tabela 4). A alta correlação (0,84) e a diferença de apenas 1,02 Mg ha<sup>-1</sup> (2,14%) entre a média do estoque estimado para cada parcela e o valor obtido pelos dados de campo, demonstraram a capacidade da RNA selecionada em modelar a variabilidade do estoque de carbono nos diferentes estágios sucessionais. A amostragem de áreas em diferentes etapas do espectro sucessional também contribuiu para o bom desempenho das RNA, pois os dados de entrada representavam adequadamente a paisagem, e continham a variabilidade do estoque de carbono observado ao longo dos fragmentos florestais (BARBOSA et al, 2014; MOLINA et al., 2016).

Foi observado que os valores de carbono generalizados a partir dos dados simulados foram consistentes, o que evidencia a eficiência da simulação de variáveis a partir das reflectâncias observadas (Figura 9). A análise gráfica permite notar que a RNA selecionada pode ser utilizada na generalização dos estoques de carbono, uma vez que não foram observadas inconsistências nas amplitudes e abrangências das predições em relação às variáveis de entrada (Figura 10). Esta informação indica a aplicabilidade da validação baseada em dados de reflectância simulados (completamente aleatórios, mas dentro da faixa de dados observados). Para bancos de dados restritos, como o do presente estudo, o benefício da validação com subamostra é insignificante diante do prejuízo em relação à redução dos dados de treinamento. Uma possibilidade teórica seria a validação cruzada *Leave-one-out*, como utilizado por Almeida et al. (2020) para validar modelagens de biomassa em aérea de Mata Atlântica secundária em Sergipe, a partir de sensor ativo aerotransportado. Entretanto, os testes realizados com esta metodologia neste estudo não foram promissores, devido à restrição de dados para cada combinação das variáveis de entrada e de saída.

O mapa de predição obtido a partir da RNA e das reflectâncias do período chuvoso (Figura 11) apresenta adequadamente a distribuição do estoque de carbono nos fragmentos florestais. Em áreas de pastagem abandonadas foram observados os menores estoques, enquanto fragmentos mais maduros, como a Mata do Paraíso e a Mata da Silvicultura,

apresentam os pontos de maior estoque. Esta constatação é sustentada pelas observações de Nunes et al. (2020), que em seu estudo na Amazônia, evidenciaram a influência da idade sucessional nos processos de estocagem e no carbono armazenado nas florestas tropicais. Estes fatores apontam para a capacidade de generalização da RNA selecionada em estimar o carbono a partir de dados de refletância do período chuvoso.

Segundo Nunes et al. (2020), florestas secundárias jovens são responsáveis pela estocagem de expressivas quantidades de carbono, mas são frequentemente negligenciadas durante o mapeamento das áreas. Neste estudo, as áreas de sucessão inicial foram consideradas e o seu estoque de carbono contabilizado (Figura 11), o que permite a compreensão da distribuição espacial e sucessional do carbono, além de contribuir para o conhecimento dos padrões de avanço das florestas secundárias. Efetivamente, o estoque observado nessas áreas é baixo, porém, a possibilidade de incremento do estoque aos níveis dos fragmentos mais maduros confirma a importância da permanência dessas formações. Além disso, mapas de predição locais ou regionais podem compor projetos de mapeamento de biomassa e carbono florestais em níveis continentais e até globais (AVITABILE et al., 2016), sustentando ações internacionais de gestão dos sumidouros.

A extensão das florestas em diferentes estágios sucessionais aumentou 18,23% na área de estudo, quando comparada à pesquisa de Almeida et al. (2016) (728,80 ha). O aumento da extensão de florestas secundárias em áreas abandonadas da Mata Atlântica pode colaborar para o cumprimento das Contribuições Nacionalmente Determinadas (NDCs) brasileiras junto ao Acordo de Paris, através da redução das emissões líquidas de carbono (POORTER et al., 2016; NUNES et al., 2020; HEINRICH et al., 2021). Esse potencial está relacionado a superioridade da produção líquida das florestas secundárias em relação às maduras, que associada às extensas áreas que ocupam nos territórios, permite a estocagem de quantidades significativas de carbono, além de contribuírem para outros processos ecológicos (LU, 2006; MASEK e COLLATZ, 2006; ANAYA; CHUVIECO; PALACIOS-ORUETA, 2009; BRANDT et al., 2012; GÜNERALP; FILIPPI; RANDALL, 2014; BONGERS et al., 2015). Essa contribuição se torna especialmente importante nos neotrópicos, onde a absorção de carbono das florestas secundárias em relação às primárias pode ser 11 vezes maior (POORTER et al., 2016). Na Mata Atlântica, o potencial de estocagem das florestas secundárias foi evidenciado para região de Viçosa, com registros de incrementos líquidos de até 2,45 Mg ha<sup>-1</sup> ano<sup>-1</sup> (ROCHA et al., 2020). Neste contexto, as florestas deste bioma devem contribuir com uma parcela significativa das

metas do Acordo de Paris, em que foi previsto que as florestas mundiais devem contribuir com 26% da mitigação climática (GRASSI et al., 2017).

Os compartimentos superficiais correspondem aos maiores estoques de carbono florestal e são os mais susceptíveis a oscilações provocadas por distúrbios humanos. A criação e aprimoramento de técnicas mais eficientes e metodologicamente menos onerosas são fundamentais para garantir o inventário e monitoramento dos estoques de carbono, e avaliar as variações oriundas de perturbações antropogênicas (BERENGUER et al., 2014). Embora ainda existam limitações, o avanço nas tecnologias de sensoriamento remoto tem sido fundamental para a medição rápida, abrangente e pouco onerosa do estoque de carbono em extensas áreas e garantir a proposição de projetos de créditos de carbono e REDD + (CASTILLO-SANTIAGO; RICKER; JONG, 2011; CLARK et al., 2011; BERENGUER et al., 2014; ZALD et al., 2016; ALMEIDA et al., 2020). Neste contexto, os resultados alcançados neste estudo evidenciam a aplicabilidade de RNA e de dados de alta resolução espacial na modelagem do estoque de carbono de florestas secundárias da Mata Atlântica. Essa demonstração é especialmente importante para a economia do Brasil, uma vez que o país lidera as projeções de geração de créditos de carbono para cumprimento das metas do Acordo de Paris (KOH et al., 2021).

## 5. CONCLUSÃO

Os fragmentos apresentam estrutura florestal e desenvolvimento sucessional adequados, demonstrado pela distribuição diamétrica em J-invertido, e pelo incremento em diâmetro, altura e carbono durante o amadurecimento da vegetação.

O estoque de carbono aumenta com o avanço do estágio sucessional, o que indica a importância da vegetação secundária na Mata Atlântica como reservatório de carbono na superfície terrestre.

As variáveis espectrais do estrato inicial e do período chuvoso apresentam as maiores correlações com o estoque de carbono. Os Índices de Vegetação não contribuem para melhoria da predição do carbono, e uso das reflectâncias BLUE, GREEN, RED e NIR do período chuvoso proporcionam estimativas consistentes.

As Redes Neurais Artificiais apresentam desempenho satisfatório na modelagem do estoque de carbono, quando as entradas do treinamento são as variáveis espectrais do período chuvoso, e validação com dados simulados.

A metodologia utilizada é eficiente para estimar o estoque de carbono arbóreo aéreo em diferentes estágios sucessionais da Mata Atlântica na Zona da Mata mineira, a partir de dados multiespectrais de alta resolução e Redes Neurais Artificiais. Os resultados direcionam as entidades públicas e privadas para a contabilização acurada dos estoques de carbono, e estabelecimento de práticas e políticas voltadas à mitigação das mudanças climáticas, cumprimento das Contribuições Nacionalmente Determinadas, e consequentemente efetivação das metas do Acordo de Paris.

## REFERÊNCIAS

ADAMU, B.; *et al.* Evaluating the accuracy of spectral indices from Sentinel-2 data for estimating forest biomass in urban areas of the tropical savanna. **Remote Sensing Applications: Society and Environment**, v. 22, p. 100484, 2021. <https://doi.org/10.1016/j.rsase.2021.100484>.

ALMEIDA, A.; *et al.* Estimating Structure and Biomass of a Secondary Atlantic Forest in Brazil Using Fourier Transforms of Vertical Profiles Derived from UAV Photogrammetry Point Clouds. **Remote Sensing**, v. 12, n. 21, p. 3560, 2020. <https://doi.org/10.3390/rs12213560>.

ALMEIDA, L. T.; *et al.* Locação de corredores ecológicos e área de preservação permanente na Universidade Federal de Viçosa. **Nativa**, v. 4, n. 6, p. 412–418, 2016. <http://dx.doi.org/10.14583/2318-7670.v04n06a12>.

AMARO, M. A. **Quantificação do estoque volumétrico, biomassa e de carbono em uma Floresta Estacional Semidecidual no município de Viçosa–MG**. 2010. 183 f. Tese (Doutorado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa–MG, 2010.

AMARO, M. A.; *et al.* Estoque volumétrico, de biomassa e de carbono em uma Floresta Estacional Semidecidual em Viçosa, Minas Gerais. **Revista Árvore**, v. 37, n. 5, p. 849–857, 2013. <https://doi.org/10.1590/S0100-67622013000500007>.

ANAYA, J. A.; CHUVIECO, E.; PALACIOS–ORUETA, A. Aboveground biomass assessment in Colombia: A remote sensing approach. **Forest Ecology and Management**, v. 257, n. 4, p. 1237–1246, 2009. <https://doi.org/10.1016/j.foreco.2008.11.016>.

AVITABILE, V.; *et al.* An integrated pantropical biomass map using multiple reference datasets. **Global Change Biology**, v. 22, p. 1406–1420, 2016. <https://doi.org/10.1111/gcb.13139>.

BACCINI, A.; *et al.* Estimated carbon dioxide emissions from tropical deforestation improved by carbon–density maps. **Nature Climate Change**, v. 2, p. 182–185, 2012. <https://doi.org/10.1038/nclimate1354>.

BARBOSA, J. M.; *et al.* Remotely sensed biomass over steep slopes: An evaluation among successional stands of the Atlantic Forest, Brazil. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 88, p. 91–100, 2014. <http://dx.doi.org/10.1016/j.isprsjprs.2013.11.019>.

BERENGUER, E.; *et al.* A large-scale field assessment of carbon stocks in human-modified tropical forests. **Global Change Biology**, v. 20, 3713–3726, 2014. <https://doi.org/10.1111/gcb.12627>.

BINOTI, M. L. S. **Emprego de redes neurais artificiais em mensuração e manejo florestal**. 2012. Tese (Doutorado em Ciências Florestais) – Universidade Federal de Viçosa, 2012.

BITTENCOURT, S. R. M.; BUSCH, S. E.; CRUZ, M. R. O Mecanismo de Desenvolvimento Limpo no Brasil. *In*: FRANGETTO, F. W.; VEIGA, A. P. B.; LUEDEMANN, G. (Orgs.). **Legado do MDL: impactos e lições aprendidas a partir da implementação do Mecanismo de Desenvolvimento Limpo no Brasil**. Brasília, DF: Instituto de Pesquisa Econômica Aplicada – IPEA, 2018. cap. 2, p. 43–58.

BOLLAS, N.; KOKINOU, E.; POLYCHRONOS, V. Comparison of Sentinel-2 and UAV Multispectral Data for Use in Precision Agriculture: An Application from Northern Greece. **Drone**, v. 5, n.2, 35, 2021. <https://doi.org/10.3390/drones5020035>.

BONGERS, F.; *et al.* The potential of secondary forests. **Science**, v. 348, n. 6235, p. 642–643, 2015. <https://doi.org/10.1126/science.348.6235.642-c>.

BORDIN, K. M.; *et al.* Climate and large-sized trees, but not diversity, drive above-ground biomass in subtropical forests. **Forest Ecology and Management**, v. 490, n. 119126, 2021. <https://doi.org/10.1016/j.foreco.2021.119126>.

BOUCHER, P. B.; *et al.* Detecting Change in Forest Structure with Simulated GEDI Lidar Waveforms: A Case Study of the Hemlock Woolly Adelgid (HWA; *Adelges tsugae*) Infestation. **Remote Sensing**, v. 12, n. 12, 1304, 2020. <https://doi.org/10.3390/rs12081304>.

BRAGA, A. J. T.; BORGES, E. E. L.; MARTINS, S. V. Florística e estrutura da comunidade arbórea de uma Floresta Estacional Semidecidual secundária em Viçosa, MG. **Revista Árvore**, v. 35, n. 3, p. 493–503, 2011. <https://doi.org/10.1590/S0100-67622011000300012>.

BRANDT, J. S.; *et al.* Using Landsat imagery to map forest change in southwest China in response to the national logging ban and ecotourism development. **Remote Sensing of Environment**, v. 121, p. 358–369, 2012. <https://doi.org/10.1016/j.rse.2012.02.010>.

BRASIL. Presidência da República. Lei no 12.187, de 29 de dezembro de 2009. Institui a Política Nacional de Mudança do Clima e dá outras providências. Diário Oficial da União, Brasília, 20 dez. 2009.

BUENO, M. L.; *et al.* Influence of edaphic factors on the floristic composition of an area of cerrado in the Brazilian centralwest. **Acta Botanica Brasilica**, v. 27, n. 2, p. 445–455, 2013. <http://dx.doi.org/10.1590/S0102-33062013000200017>.

CALIMAN, J. P.; *et al.* Temporal and spatial variability of the diameter distribution in a secondary Brazilian Atlantic Forest suggests site-specific. **Revista Árvore**, v. 44, n. e4406, 2020. <http://dx.doi.org/10.1590/1806-9088202000000006>.

CAMPOS, J. C. C.; LEITE, H. G. **Mensuração Florestal: perguntas e respostas**. 5. ed. Viçosa, MG: Ed. UFV, 2017. 636 p.

CASSOL, H. L. G.; SALDANHA, D. L.; KUPLICH, T. M. Inventário de carbono em fragmento de Floresta Ombrófila Mista por detecção remota. **Floresta**, v. 44, n. 4, p. 697–708, 2014. <http://dx.doi.org/10.5380/ufv.v44i4.33014>.

CASTILLO–SANTIAGO, M. A.; RICKER, M.; JONG, B. H. J. Estimation of tropical forest structure from SPOT–5 satellite images. **International Journal of Remote Sensing**, v. 31, n. 10, p. 2767–2782, 2010. <https://doi.org/10.1080/01431160903095460>.

CLARK, M. L.; *et al.* Estimation of tropical rain forest aboveground biomass with small-footprint lidar and hyperspectral sensors. **Remote Sensing of Environment**, v. 115, n. 11, p. 2931–2942, 2011. <https://doi.org/10.1016/j.rse.2010.08.029>.

CORREA, G. F. **Modelo de evolução e mineralogia da fração argila de solos do planalto de Viçosa, MG**. 1984. 87 f. Dissertação (Mestrado em Solos) – Universidade Federal de Viçosa, Viçosa–MG, 1984.

CUNHA, G. M.; *et al.* Biomassa e estoque de carbono e nutrientes em Florestas Montanas da Mata Atlântica na Região Norte do estado do Rio de Janeiro. **Revista Brasileira de Ciência do Solo**, v. 33, n. 5, p. 1175–1185, 2009. <https://doi.org/10.1590/S0100-06832009000500011>.

DOMINGUES, G. F.; *et al.* Artificial neural networks on integrated multispectral and SAR data for high-performance prediction of eucalyptus biomass. **Computers and Electronics in Agriculture**, v. 168, 105089, 2020. <https://doi.org/10.1016/j.compag.2019.105089>.

DRUSCH, M.; *et al.* Sentinel-2: ESA's optical high-resolution mission for GMES operational services. **Remote Sensing of Environment**, v. 120, p. 25–36, 2012. <https://doi.org/10.1016/j.rse.2011.11.026>.

ESA – Agência Espacial Europeia. **Manual do usuário do Sentinel–2**. Agência Espacial Europeia: Paris, França, 2015.

FERRAZ, A. S.; *et al.* Estimativa do Estoque de Biomassa em um Estimativa do Estoque de Biomassa em um Fragmento Florestal Usando Imagens Orbitais. **Floresta e Ambiente**, v. 21, n. 3, p. 286–296, 2014. <https://doi.org/10.1590/2179-8087.052213>.

FIORENTIN, L. D.; *et al.* Quantificação e modelagem da biomassa e carbono da regeneração natural em área de Floresta Ombrófila Mista. **Revista Brasileira de Biometria**, v. 33, n. 2, p. 251–267, 2015.

FOSTER, G. L.; ROYER, D. L.; LUNT, D. J. Future climate forcing potentially without precedent in the last 420 million years. **Nature Communications**, v. 8, n. 14845, 2017. <https://doi.org/10.1038/ncomms14845>.

GASPAR, R. O.; *et al.* Análise fitossociológica e do estoque de carbono no estrato arbóreo de um fragmento de Floresta Estacional Semidecidual. **Ciência Florestal**, v. 24, n. 2, p. 313–324, 2014. <https://doi.org/10.5902/1980509814569>.

GIBBS, H. K.; *et al.* Monitoring and estimating tropical forest carbon stocks: making REDD a reality. **Environmental Research Letters**, v. 2, n. 045023, p. 1–13, 2007. <https://doi.org/10.1088/1748-9326/2/4/045023>.

GRASSI, G.; *et al.* The key role of forests in meeting climate targets requires science for credible mitigation. **Nature Climate Change**, v. 7, p. 220–226, 2017. <https://doi.org/10.1038/nclimate3227>.

GAUSMAN, H. W.; RODRIGUEZ, R. R.; RICHARDSON, A. J. Infinite Reflectance of Dead Compared with Live Vegetation. **Agronomy Journal**, v. 68, p. 295–296, 1976. <https://doi.org/10.2134/agronj1976.00021962006800020023x>.

GÜNERALP, İ.; FILIPPI, A. M.; RANDALL, J. Estimation of floodplain aboveground biomass using multispectral remote sensing and nonparametric modeling. **International Journal of Applied Earth Observation and Geoinformation**, v. 33, n. 1, p. 119–126, 2014. <https://doi.org/10.1016/j.jag.2014.05.004>.

HEINRICH, V. H. A.; *et al.* Large carbon sink potential of secondary forests in the Brazilian Amazon to mitigate climate change. **Nature Communications**, v. 12, n. 1785, 2021. <https://doi.org/10.1038/s41467-021-22050-1>.

HUETE, A. A soil-adjusted vegetation index (SAVI). **Remote Sensing of Environment**, v. 25, n. 3, p. 295–309, 1988. [https://doi.org/10.1016/0034-4257\(88\)90106-X](https://doi.org/10.1016/0034-4257(88)90106-X).

HUETE, A.; JUSTICE, C.; LIU, H. Development of vegetation and soil indices for MODIS–EOS. **Remote Sensing of Environment**, v. 49, n. 3, p. 224–234, 1994. [https://doi.org/10.1016/0034-4257\(94\)90018-3](https://doi.org/10.1016/0034-4257(94)90018-3).

KOH, L. P.; *et al.* Carbon prospecting in tropical forests for climate change mitigation. **Nature Communications**, v. 12, n. 1271, 2021. <https://doi.org/10.1038/s41467-021-21560-2>.

LAURIN, G. V.; *et al.* Above ground biomass estimation in an African tropical forest with lidar and hyperspectral data. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 89, p. 49–58, 2014. <https://doi.org/10.1016/j.isprsjprs.2014.01.001>.

LAURIN, G. V.; *et al.* Potential of ALOS2 and NDVI to Estimate Forest Above–Ground Biomass, and Comparison with Lidar–Derived Estimates. **Remote Sensing**, v. 9, n. 1, 18, 2017. <https://doi.org/10.3390/rs9010018>.

LEAK, W. B. **Origin of sigmoid diameter distributions**. Newtown Square, PA: U.S. Department of Agriculture, Forest Service, Northeastern Research Station, 2002. 10 p.

LEAL–FILHO, N. **Caracterização do banco de sementes de três estádios de uma sucessão vegetal na Zona da Mata de Minas Gerais**. 1992. 116 f. Dissertação (Mestrado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa–MG, 1992.

LEITE, H. G.; OLIVEIRA, F. H. T. Statistical procedure to test the identity of analytical methods. **Communications in Soil Science and Plant Analysis**, v. 33, n. 7–8, p. 1105–1118, 2002. <https://doi.org/10.1081/CSS-120003875>.

LIMA, J. A. S.; *et al.* Biomassa radicular fina em fragmentos da Mata Atlântica fluminense. **Floresta**, v. 41, n. 1, p. 27–38, 2011. <http://dx.doi.org/10.5380/ufv.v41i1.21177>.

LIMA, R. A. F.; *et al.* The erosion of biodiversity and biomass in the Atlantic Forest biodiversity hotspot. **Nature Communications**, v. 11, n. 6347, 2020. <https://doi.org/10.1038/s41467-020-20217-w>.

LIU, J.; *et al.* Contrasting carbon cycle responses of the tropical continents to the 2015–2016 El Niño. **Science**, v. 358, n. 6360, eaam5690, 2017. <https://doi.org/10.1126/science.aam5690>.

LU, D. Aboveground biomass estimation using Landsat TM data in the Brazilian Amazon. **International Journal of Remote Sensing**, v. 26, n. 12, p. 2509–2525, 2005. <https://doi.org/10.1080/01431160500142145>.

LU, D. The potential and challenge of remote sensing–based biomass estimation. **International Journal of Remote Sensing**, v. 27, n. 7, p. 1297–1328, 2006. <https://doi.org/10.1080/01431160500486732>.

LU, D.; *et al.* A survey of remote sensing–based aboveground biomass estimation methods in forest ecosystems. **International Journal of Digital Earth**, v. 9, n. 1, p. 63–105, 2016. <https://doi.org/10.1080/17538947.2014.990526>.

LUTZ, J. A.; *et al.* Global importance of large–diameter trees. **Global Ecology and Biogeography**, v. 27, p. 849–864, 2018. <https://doi.org/10.1111/geb.12747>.

MAIN–KNORN, M.; *et al.* Monitoring coniferous forest biomass change using a Landsat trajectory–based approach. **Remote Sensing of Environment**, v. 139, n. 4, p. 277–290, 2013. <https://doi.org/10.1016/j.rse.2013.08.010>.

MAIN–KNORN, M.; *et al.* Evaluating the Remote Sensing and Inventory–Based Estimation of Biomass in the Western Carpathians. **Remote Sensing**, v. 3, n. 7, p. 1427–1446, 2011. <https://doi.org/10.3390/rs3071427>.

MARQUES, F. N. A. O MDL Florestal no Brasil: fundamentos, legado e elementos para o futuro. *In*: FRANGETTO, F. W.; VEIGA, A. P. B.; LUEDEMANN, G. (Orgs.). **Legado do MDL: impactos e lições aprendidas a partir da implementação do Mecanismo de Desenvolvimento Limpo no Brasil**. Brasília, DF: Instituto de Pesquisa Econômica Aplicada – IPEA, 2018. cap. 6, p. 131–180.

MASEK, J. G.; COLLATZ, G. J. Estimating forest carbon fluxes in a disturbed southeastern landscape: Integration of remote sensing, forest inventory, and biogeochemical modeling. **Journal of Geophysical Research**, v. 111, G01006, p. 1–15, 2006. <https://doi.org/10.1029/2005JG000062>.

MEIRA–NETO, J. A. A.; MARTINS, F. R. Estrutura do sub–bosque herbáceo–arbustivo da Mata da Silvicultura, uma Floresta Estacional Semidecidual no município de Viçosa–MG. **Revista Árvore**, v. 27, n. 4, p. 459–471, 2003. <https://doi.org/10.1590/S0100-67622003000400006>.

MELO, A. L. P.; SILVA, B. S. Projeto PMR Brasil: perspectivas sobre o mercado brasileiro de redução de emissões. *In*: FRANGETTO, F. W.; VEIGA, A. P. B.; LUEDEMANN, G. (Orgs.). **Legado do MDL: impactos e lições aprendidas a partir da implementação do Mecanismo de Desenvolvimento Limpo no Brasil**. Brasília, DF: Instituto de Pesquisa Econômica Aplicada – IPEA, 2018. cap. 15, p. 357–375.

MOLINA, P. X.; *et al.* Spatially–Explicit Testing of a General Aboveground Carbon Density Estimation Model in a Western Amazonian Forest Using Airborne LiDAR. **Remote Sensing**, v. 8, n. 1, 9, 2016. <https://doi.org/10.3390/rs8010009>.

MORAIS–JUNIOR, V. T. M.; *et al.* Early assessment of tree species with potential for carbon offset plantations in degraded area from the southeastern Brazil. **Ecological Indicators**, v. 98, p. 854–860, 2019. <https://doi.org/10.1016/j.ecolind.2018.12.004>.

NUNES, S.; *et al.* Unmasking secondary vegetation dynamics in the Brazilian Amazon. **Environmental Research Letters**, v. 15, n. 034057, 2020. <https://doi.org/10.1088/1748-9326/ab76db>.

OLIVEIRA, A. S.; MIGUEZ, J. D. G.; ANDRADE, T. C. M. A. A convenção sobre mudança do clima e o seu Protocolo de Quioto como indutores de ação. *In*: FRANGETTO, F. W.; VEIGA, A. P. B.; LUEDEMANN, G. (Orgs.). **Legado do MDL: impactos e lições aprendidas a partir da implementação do Mecanismo de Desenvolvimento Limpo no Brasil**. Brasília, DF: Instituto de Pesquisa Econômica Aplicada – IPEA, 2018. cap. 1, p. 21–42.

PELOSO, R. V. D. **Dinâmica e sucessão de um fragmento de Floresta Atlântica**. 2012. 187 f. Dissertação (Mestrado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa–MG, 2012.

PFLUGMACHER, D.; *et al.* Using Landsat–derived disturbance and recovery history and lidar to map forest biomass dynamics. **Remote Sensing of Environment**, v. 151, p. 124–137, 2014. <http://dx.doi.org/10.1016/j.rse.2013.05.033>.

PHILLIPS, O. L.; *et al.* Drought Sensitivity of the Amazon Rainforest. **Science**, v. 323, n. 5919, p. 1344–1347, 2009. <https://doi.org/10.1126/science.1164033>.

POORTER, L.; *et al.* Biomass resilience of Neotropical secondary forests. **Nature**, v. 530, p. 211–214, 2016. <https://doi.org/10.1038/nature16512>.

POORTER, L.; *et al.* Diversity enhances carbon storage in tropical forests. **Global Ecology and Biogeography**, v. 24, p. 1314–1328, 2015. <https://doi.org/10.1111/geb.12364>.

POWELL, S. L.; *et al.* Quantification of live aboveground forest biomass dynamics with Landsat time–series and field inventory data: A comparison of empirical modeling approaches. **Remote Sensing of Environment**, v. 114, n. 5, p. 1053–1068, 2010. <https://doi.org/10.1016/j.rse.2009.12.018>.

REX, F. E.; *et al.* Comparison of Statistical Modelling Approaches for Estimating Tropical Forest Aboveground Biomass Stock and Reporting Their Changes in Low–Intensity Logging Areas Using Multi–Temporal LiDAR Data. **Remote Sensing**, v. 12, n. 9, 1498, 2020. <https://doi.org/10.3390/rs12091498>.

REZENDE, C. L.; *et al.* From hotspot to hopespot: An opportunity for the Brazilian Atlantic Forest. **Perspectives in Ecology and Conservation**, v. 16, n. 4, p. 208–214, 2018. <https://doi.org/10.1016/j.pecon.2018.10.002>.

REZENDE, S. B. **Estudo de crono-toposequência em Viçosa – Minas Gerais**. 1971, 71 f. Dissertação (Mestrado em Fitotecnia) – Universidade Federal de Viçosa, Viçosa – MG, 1971.

RIBEIRO, S. C.; *et al.* Quantificação de biomassa e estimativa de estoque de carbono em uma floresta madura no município de Viçosa, Minas Gerais. **Revista Árvore**, v. 33, n. 5, p. 917–926, 2009. <https://doi.org/10.1590/S0100-67622009000500014>.

RIBEIRO, S. C.; *et al.* Quantificação de biomassa e estimativa de estoque de carbono em uma capoeira da Zona da Mata Mineira. **Revista Árvore**, v. 34, n. 3, p. 495–504, 2010. <https://doi.org/10.1590/S0100-67622010000300013>.

RIEDMILLER, M.; BRAUN, H. A direct adaptive method for faster backpropagation learning: the RPROP algorithm. In: RUSPINI, E. H. (Ed.), **Proceedings of the IEEE International Conference on Neural Networks**. New York: IEEE Press, 1993. p. 586–591.

ROCHA, S. J. S. S.; *et al.* Drought effects on carbon dynamics of trees in a secondary Atlantic Forest. **Forest Ecology and Management**, v. 465, n. 118097, 2020. <https://doi.org/10.1016/j.foreco.2020.118097>.

ROUSE-JUNIOR, J. W.; *et al.* **Monitoring vegetation systems in the great plains with ERTS**. In: Earth Resources Technology Satellite Symposium, 3, 1973, Washington. Proceedings. Washington: NASA, v. 1, p. 309–317.

SAATCHI, S. S.; *et al.* Benchmark map of forest carbon stocks in tropical regions across three continents. **Proceedings of the National Academy of Sciences**, v. 108, n. 24, p. 9899–9904, 2011. <https://doi.org/10.1073/pnas.1019576108>.

SEVILHA, A. C.; *et al.* Fitossociologia do estrato arbóreo de um trecho de Floresta Estacional Semidecidual no Jardim Botânico da Universidade Federal de Viçosa (face Sudoeste), Viçosa, Minas Gerais. **Revista Árvore**, v. 25, n. 4, p. 431–443, 2001. <https://doi.org/10.1590/S0100-67622002000300009>.

SILVA-JÚNIOR, M. C. Fitossociologia e estrutura diamétrica na mata de galeria do Pitoco, na Reserva Ecológica do IBGE, DF. **Cerne**, v. 11, n. 2, p. 147–158, 2005.

SILVEIRA, E. M. O.; *et al.* Modelling aboveground biomass in forest remnants of the Brazilian Atlantic Forest using remote sensing, environmental and terrain-related data. **Geocarto International**, v. 36, n. 3, p. 281–298, 2021. <https://doi.org/10.1080/10106049.2019.1594394>.

SOTHE, C.; *et al.* Evaluating Sentinel-2 and Landsat-8 Data to Map Successional Forest Stages in a Subtropical Forest in Southern Brazil. **Remote Sensing**, v. 9, n. 8, 838, 2017. <https://doi.org/10.3390/rs9080838>.

SULLIVAN, M. J. P.; *et al.* Long-term thermal sensitivity of Earth's tropical forests. **Science**, v. 368, n. 6493, p. 869–874, 2020. <https://doi.org/10.1126/science.aaw7578>.

TORRES, C. M. M. E.; *et al.* Quantificação de biomassa e estocagem de carbono em uma Floresta Estacional Semidecidual, no Parque Tecnológico de Viçosa, MG. **Revista Árvore**, v. 37, n. 4, p. 647–655, 2013. <https://doi.org/10.1590/S0100-67622013000400008>.

UFV – Universidade Federal de Viçosa. Departamento de Engenharia Agrícola. Estação Climatológica Principal de Viçosa. **Boletim meteorológico 2016**. Viçosa, MG: UFRV, 2016.

VELOSO, H. P.; RANGEL-FILHO, A. L. R.; LIMA, J. C. A. **Classificação da vegetação brasileira adaptada a um sistema universal**. Rio de Janeiro: IBGE, 1991. 123 p.

VIANA, R. H. O.; *et al.* Florística e análise comparativa de comunidades de Floresta Estacional Semidecidual Montana em Viçosa – MG. **Interface**, v. 9, p. 131–146, 2015.

VILLANOVA, P. H.; *et al.* Necromass Carbon Stock in a Secondary Atlantic Forest Fragment in Brazil. **Forests**, v. 10, n. 10, p. 833, 2019. <https://doi.org/10.3390/f10100833>.

WANG, C.; *et al.* Impact of spectral saturation on leaf area index and aboveground biomass estimation of winter wheat. **Spectroscopy Letters**, v. 49, n. 4, p. 241–248, 2016. <http://dx.doi.org/10.1080/00387010.2015.1133652>.

WANG, J.; RICH, P. M.; PRICE, K. P. Temporal responses of NDVI to precipitation and temperature in the central Great Plains, USA, **International Journal of Remote Sensing**, v. 24, n. 11, p. 2345–2364, 2003. <https://doi.org/10.1080/01431160210154812>.

WATZLAWICK, L. F.; *et al.* Estimate of the diameter distribution in Mixed Ombrophylous Forest fragment with the Meyer's function. **Applied Research & Agrotecnology**, v. 6, n. 1, p. 29–36, 2013.

WATZLAWICK, L. F.; KIRCHNER, F. F.; SANQUETTA, C. R. Estimativa de biomassa e carbono em Floresta com Araucária utilizando imagens do satélite IKONOS II. **Ciência Florestal**, v. 19, n. 2, p. 169–181, 2009. <https://doi.org/10.5902/19805098408>.

WILSON, B. T.; WOODALL, C. W.; GRIFFITH, D. M. Imputing forest carbon stock estimates from inventory plots to a nationally continuous coverage. **Carbon Balance and Management**, v. 8, n. 1, p. 1–15, 2013. <https://doi.org/10.1186/1750-0680-8-1>.

YANG, K.; *et al.* Combining spectral and texture features of UAV images for the remote estimation of rice LAI throughout the entire growing season. **Remote Sensing**, v. 13, n. 15, 3001, 2021. <https://doi.org/10.3390/rs13153001>.

ZALD, H. S. J.; *et al.* Integrating Landsat pixel composites and change metrics with lidar plots to predictively map forest structure and aboveground biomass in Saskatchewan, Canada. **Remote Sensing of Environment**, v. 176, p. 188–201, 2016. <https://doi.org/10.1016/j.rse.2016.01.015>.

ZHANG, J.; *et al.* Estimating aboveground biomass of *Pinus densata*-dominated forests using Landsat time series and permanent sample plot data. **Journal of Forestry Research**, v. 30, n. 5, p. 1689–1706, 2019. <https://doi.org/10.1007/s11676-018-0713-7>.

ZHU, X.; LIU, D. Improving forest aboveground biomass estimation using seasonal Landsat NDVI time-series. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 102, p. 222–231, 2015. <https://doi.org/10.1016/j.isprsjprs.2014.08.014>.

ZOLKOS, S. G.; GOETZ, S. J.; DUBAYAH, R. A meta-analysis of terrestrial aboveground biomass estimation using lidar remote sensing. **Remote Sensing of Environment**, v. 128, p. 289–298, 2013. <http://dx.doi.org/10.1016/j.rse.2012.10.017>.

## APÊNDICE A

### Características da Rede Neural Artificial (RNA) selecionada, com as variáveis de reflectância do período chuvoso.

---

#### Características Gerais

---

Número de Neurônios na Camada Oculta = 8  
 Número de Neurônios na Camada de Saída = 1  
 Número de Neurônios na Camada de Entrada = 5  
 Função de Ativação da Camada Oculta = Sigmoidal (Logística)  
 Função de Ativação da Camada de Saída = Sigmoidal (Logística)  
 Valor de Convergência = 20  
 Número de K-Fold = 4  
 Número de RNA treinadas = 50  
 Tipo de Algoritmo de treinamento = Resilient Propagation  
 Número de Ciclos de Treinamento = 3000  
 Taxa de Aprendizado Backpropagation = 0.01  
 Taxa de momentum Backpropagation = 0.005  
 Ajuste Taxa de Aprendizado = false  
 Ajuste Momentum = false  
 Taxa de aprendizagem Manhattan = 0.00001  
 Taxa de aprendizagem Quick = 2.0  
 População Algoritmo Genéticos = 500  
 Temperatura Máxima SA = 10  
 Temperatura Mínima SA = 2  
 Ciclos SA = 500  
 População NEAT = 1000  
 Densidade NEAT = 0.1  
 População PSO = 100  
 População HyperNeat = 500  
 Densidade HyperNeat = 4  
 Free Form Recorrência = false  
 RBF Dimensões = 2  
 RBF Número de Dimensões = 7  
 RBF Treinamento RPROP = false  
 RBF Singular Value Decomposition = true  
 Elman Greedy = false  
 Elman Hybrid = false  
 Jordan Greedy = false  
 Hybrid Greedy = false  
 Epsilon SVM = false  
 nu SVM = true  
 Kernel Polinomial = false  
 Kernel Linear = true  
 Kernel Precomputer = false  
 Kernel RBF = false  
 Kernel Sigmoidal = false  
 Nelder Mead step = 100  
 Gaussian Kernel PNN = true  
 Reciprocal Kernel PNN = false

---

<b>Descrição das Variáveis</b>		
Variáveis Categóricas	Variáveis Contínuas	Variáveis Saída
	BLUE d	Carbono
	GREEN d	
	RED d	
	NIR d	
<b>Pesos</b>		
I0-->H0,0 : -1.8153502567705446	I3-->H0,5 : 32.44476876006903	
I0-->H0,1 : -6.287385935741478	I3-->H0,6 : -1.6902801550835274	
I0-->H0,2 : -16.948992890799648	I3-->H0,7 : 8.266239439696653	
I0-->H0,3 : 18.89573075295849	I4-->H0,0 : -2.133548305918271	
I0-->H0,4 : 203.13308161703782	I4-->H0,1 : -0.5797958047303117	
I0-->H0,5 : -17.51856159385858	I4-->H0,2 : -0.3907069872204767	
I0-->H0,6 : -2.0818100738586724	I4-->H0,3 : -0.717871208374028	
I0-->H0,7 : -0.8244922564958399	I4-->H0,4 : 0.5990430480194533	
I1-->H0,0 : 4.312182275462462	I4-->H0,5 : 0.8078615524397816	
I1-->H0,1 : 21.024230749146113	I4-->H0,6 : 0.17750074332628923	
I1-->H0,2 : -23.654038775245365	I4-->H0,7 : 0.8468219134494671	
I1-->H0,3 : 6.778708707630757	bias-->H0,0 : -1.2072175782278303	
I1-->H0,4 : -10.11208238943084	bias-->H0,1 : -1.4424990299193865	
I1-->H0,5 : 5.295083719099589	bias-->H0,2 : -0.3092416986456603	
I1-->H0,6 : -9.543263687320136	bias-->H0,3 : 0.7004575587888753	
I1-->H0,7 : -5.060865911409458	bias-->H0,4 : -0.20363416559444145	
I2-->H0,0 : 1.6328487230527096	bias-->H0,5 : 0.2549583638363405	
I2-->H0,1 : 0.40849367422528365	bias-->H0,6 : 0.4921678806046418	
I2-->H0,2 : -36.52110613305408	bias-->H0,7 : 0.7539838459579659	
I2-->H0,3 : 8.20260485346175	H0,0-->O0 : -4.399396106307713	
I2-->H0,4 : -415.65657245213293	H0,1-->O0 : 1.6047614697292105	
I2-->H0,5 : -1.7333204972785237	H0,2-->O0 : 2.761269724502756	
I2-->H0,6 : 7.743220897327821	H0,3-->O0 : -4.317536231848969	
I2-->H0,7 : -3.7720113491636718	H0,4-->O0 : 6.100799941169273	
I3-->H0,0 : -3.707110715273828	H0,5-->O0 : -4.816726005521425	
I3-->H0,1 : 0.5934149714196152	H0,6-->O0 : 5.482314081806528	
I3-->H0,2 : 23.615665168850555	H0,7-->O0 : 2.5717587699517814	
I3-->H0,3 : -86.71619581607322	bias-->O0 : -0.5593516639206436	
I3-->H0,4 : 26.46648781010072		